

基于局部自适应逼近的半监督反馈算法

黄传波¹ 向丽² 金忠¹

(南京理工大学计算机科学与技术学院 南京 210094)¹ (重庆师范大学影视传媒学院 重庆 400047)²

摘要 将鉴别信息引入到距离测度中,利用这个新的局部距离测度代替欧氏距离构建 k -近邻,提出一种新的局部线性近邻扩展算法。将此用于图像检索的相关反馈机制,产生基于局部自适应逼近的半监督反馈算法 FLANNP(feedback locally adaptive nearest neighbor propagation)。该方法首先由支持向量机构建的判别函数来确定最优判别方向,基于此方向产生一个局部自适应距离算法,进而确定数据点间的权重。最后,标签信息由全局一致性假设,通过局部最近邻,从有标签数据点开始进行全局扩散标注。该方法使用有鉴别信息的距离测度,提高了图像检索的准确度。

关键词 相关反馈,半监督学习,局部自适应逼近,线性近邻扩展

中图分类号 TP118 **文献标识码** A

Semi-supervised Feedback Algorithm Based on Locally Adaptive Approximation

HUANG Chuan-bo¹ XIANG Li² JIN Zhong¹

(Department of Computer Science, Nanjing University of Science and Technology, Nanjing 210094, China)¹

(Film&Media Academy, Chongqing Normal University, Chongqing 400047, China)²

Abstract In this paper, identification information was put into the distance measure, using this new distance measure instead of the Euclidean distance to construct k -neighbor, we proposed a new local linear nearest neighborhood propagation method. This provides a semi-supervised feedback algorithm based on the local adaptive approximation for image retrieval relevance feedback mechanism FLANNP (feedback locally adaptive nearest neighbor propagation). The decision function constructed by SVMs was used to determine the most discriminant direction in a neighborhood around the query. Such a direction provides a local adaptive distance algorithm. By this the reconstruction weights were computed. After all the labels were propagated from the labeled points to the whole dataset using the local linear neighborhoods with sufficient smoothness. The approach makes use of identification information in distance measure and improves the accuracy of image retrieval.

Keywords Relevance feedback, Semi-supervised learning, Locally adapt approximating, Linear neighborhood propagation

1 引言

半监督学习是近年来机器学习领域的一个研究热点。半监督学习^[1]是一种同时利用标记和未标记数据的算法,其基本思想是利用一些分布上的假设,对未标记数据的标记进行预测,然后合并到标记的数据中去,训练新的分类器以达到更好的效果。主要的半监督学习有半监督 EM 算法^[2]、协同训练(Co-Training)算法^[3]、Tri-Training 算法^[4]、直推式支持向量机^[5]、基于图的方法等。Co-Training 算法是通过两个在不同视图下的数据集进行学习的分类器之间的交互来提高分类器的精确程度,未标记的数据被分类器逐步标记,选出最确信的加入训练集。如此不断重复,直到未标记集全部标记为止。在 Co-Training 的基础上 Zhou 等人提出在单一视图上利用 3 个分类器进行半监督学习的 Tri-Training 方法^[4]。在很多实

际应用中,随着数据采集技术和存储技术的发展,获取大量的无标签样本已变得非常容易,而获取有标签样本通常需要付出很大的代价,因而相对于大量的无标签样本,有标签的样本通常会很少。传统的无监督学习只能利用无标签样本学习,监督学习则只利用少量的有标签样本学习,而半监督学习的优越性体现在能够同时利用大量的无标签样本和少量的有标签样本进行学习。

在 CBIR 过程中,即使将用户在相关反馈过程中提供的信息考虑进来,有标签图像的数目仍然是比较少的。但图像库中却通常存在大量的图像,这些图像都是未标记的,因为在查询之前无法事先判断它们是否与查询相关。显然, CBIR 任务是典型的有标签示例很少、未标记示例非常多的任务。因此,基于内容的图像检索是利用未标记示例的学习技术的很好的试验场,另一方面通过引入这些学习技术可能有助于突

到稿日期:2009-08-05 返修日期:2009-10-16 本文受国家 863 高技术研究发展计划(No. 2006AA01Z119),国家自然科学基金(No. 60473039)资助。

黄传波(1972-),男,博士生,主要研究方向为模式识别与图像处理等,E-mail:huangjunfengcq@126.com;向丽(1965-),女,讲师,主要研究方向为摄影艺术及图像处理技术等;金忠(1961-),男,博士生导师,主要研究方向为模式识别、图像处理等。

破 CBIR 的技术瓶颈^[6]。

通过以上分析,我们提出了一种基于图的局部自适应逼近半监督反馈学习算法 FLANNP(feedback locally adaptive nearest neighbor propagation)。算法利用了流形假设,将用户标记的样本作为训练集,利用样本的分类信息在某个邻域内学习一个合适距离测度,使得在这个测度意义下类内凝聚、类间散布。进而利用这个距离测度建立一个图,图中结点对应(有标签或未标签)数据点,边为数据点间的相似度,然后通过迭代算法优化标签传递函数在图上的光滑性来获取无标签数据点的标签。

2 局部自适应距离测度

由支持向量机找到最大间隔边界,用以确定查询点附近局部邻域判别方向。一般,此方向平行于将两类分开的最好的方向。

2.1 问题分析与算式确定

SVM 分类模式基于符号函数 $\text{sign}(f(x))$ 。显然,在非线性特征映射 Φ 的情况下,SVM 分类器将在输入空间中给出一个非线性边界 $f(x)=0$ 。在曲面 $f(x)=0$ 上的任一点 d 计算出的梯度向量 $n_d = \nabla_d f$ 指向输入空间在点 d 的决定边界的垂直方向,如图 1 所示。

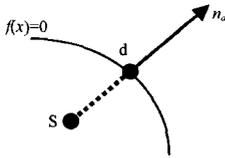


图 1 垂直距离和梯度向量

因此,向量 n_d 确定了输入空间训练集数据在 d 的邻域被很好分开的方向,由梯度向量 n_d 所给的方向和任何接近它的方向将带有很好的分类鉴别信息。

假定 q 为我们要预测的标签的查询点, q 接近边界,这样类条件概率变为局部非均匀的,此时估测局部特征相关性变得很关键。如果 p 是边界 $f(x)=0$ 上距查询点 q 最近的点,即:

$$\begin{cases} d(q, p) = \arg \min_p \|q - p\| \\ \text{st. } f(p) = 0 \end{cases} \quad (1)$$

显然,梯度 n_d 确定了最优鉴别方向。

事实上,梯度向量确定的方向,在查询点附近沿着这个方向投影训练数据能够被很好地分开。形式上,我们能够考虑点乘 $n_d^T t$ 度量方向 t 与 n_d 的密切程度。特别是,用 e_j 表示沿着输入特征 j 的单位向量,在此 $j=1, 2, \dots, D$ (D 为数据特征向量的维数),我们能够定义一个在 q 局部对应特征 j 的相关性度量:

$$R_j(q) = |e_j^T n_d| = |n_{d,j}| \quad (2)$$

式中, $n_d = (n_{d,1}, n_{d,2}, \dots, n_{d,D})^T$ 。相对特征相关性的度量,按照加权方法可以由下式给出:

$$r_j(q) = \frac{\exp(\beta R_j(q))}{\sum_{i=1}^D \exp(\beta R_i(q))} \quad (3)$$

式中, β 是一个参数,能够通过最大化(最小化) R_j 对 r_j 的影响来选择。当 $\beta=0$ 时, $r_j = 1/D$,从而忽略了 R_j 之间的任何差别;当 β 较大时, R_j 的变化将呈指数地影响 r_j 。指数加权

对局部特征的相关性的变化更敏感,一般情况下能使优良性能有所提高。事实上,指数加权方法是传递稳定的,能够阻止邻域在任何的方向无限扩展。那么,式(3)可以用作与特征相联系的权重来计算权值距离:

$$D(x_i, x_j) = \sqrt{\sum_{k=1}^D r_k(x_{ik} - x_{jk})^2} \quad (4)$$

这些权重能够使邻域在不重要的特征维伸展,同时在最具有影响的特征维收缩。

权重方法 $r_j(q)$ 是基于局部(q 的邻域)决定边界方向的。事实上,权重 $r_j(q)$ 带的信息可看作在 q 局部邻域的形状应当怎样收缩和伸展。我们希望邻域沿着对应梯度的方向收缩,并沿垂直于梯度方向的维伸展。因此,局部自适应最近邻算法能够使我们在分类过程中(根据学习权重尺度)只考虑最近邻。

2.2 参数 β 的确定

我们希望参数 β 在指数加权方法随着 q 与边界的距离减小而增加,利用支持向量位于边界面附近的知识,可以通过计算查询点 q 与最近邻支持向量的距离估算它距边界的距离:

$$B_q = \min_{s_i} \|q - s_i\| \quad (5)$$

式中,最小化是替代无约束($0 < a_i < C$)支持向量 s_i 。在边界附近的空分辨率通过扩大支持向量邻域的局部体积单元来增加^[7]。那么,可以利用下式达到我们的目的:

$$\beta = H - B_q \quad (6)$$

式中, H 是一个参数,等于训练点 x 与边界的近似平均距离:

$$H = \frac{1}{l} \sum_x \min_{s_i} \|x - s_i\| \quad (7)$$

那么, β 的值就可以根据其其与边界的相对位置很好地适应每个查询点。查询点 q 距决定边界越近,在距离计算中 R_j 受到的影响就越大。

3 LANNP 算法 (locally adaptive nearest neighbor propagation)

本文提出的 LANNP 算法,使用有鉴别信息的距离测度来代替欧式距离测度计算 k -近邻,将先验鉴别信息引入到 k -近邻块中,增大不同类间的间隔,提高流形学习的泛化能力。首先是用自适应局部权值距离算法计算每个点的 k -近邻,然后用一系列重叠的近邻块来逼近整个图,最后合并所有边权值,形成整个图的权重矩阵。

3.1 构造图

假设 $X = \{x_1, x_2, \dots, x_l, x_{l+1}, \dots, x_n\}$ 表示 R^D 空间的 n 个图像点的集合, $Y = \{1, -1\}$ 是标签集合,前 l 个点 $x_i \in X$ ($i \leq l$) 是有标签点,表示为 $y_i \in Y$,其余点 $x_u \in X$ ($l+1 \leq u \leq n$) 是无标签的点。

LANNP 不像传统基于图的方法那样考虑成对点之间的关系,而是利用每个点的近邻信息来构建 G 。利用自适应局部权值距离算法,计算点的 k -近邻,借助 LLE 方法,假定这些近邻点是线性的,也就是说,每个图像点能通过它邻近点的线性组合来优化重构。因此,可以将其转化为极小化式^[8]:

$$\epsilon = \sum_{i=1}^n \|x_i - \sum_{j: x_j \in N(x_i)} w_{ij} x_j\|^2 \quad (8)$$

式中, $N(x_i)$ 表示 x_i 的近邻点数, w_{ij} 是 x_j 对 x_i 的贡献。

我们添加两个限制条件, $\sum_{j \in N(x_i)} w_{ij} = 1$, $w_{ij} \geq 0$,显然, x_j

与 x_i 越相似, w_{ij} 值就越大。因此, w_{ij} 可以用来度量 x_i 与 x_j 的相似性。在此需要解决的一个问题就是有时 $w_{ij} \neq w_{ji}$, 这是很容易的, 具体如下:

$$\begin{aligned} \epsilon_i &= \left\| x_i - \sum_{j: x_j \in N(x_i)} w_{ij} x_j \right\|^2 \\ &= \left\| \sum_{j: x_j \in N(x_i)} w_{ij} (x_i - x_j) \right\|^2 \\ &= \sum_{j, k: x_j, x_k \in N(x_i)} w_{ij} w_{ik} (x_i - x_j)^T (x_i - x_k) \\ &= \sum_{j, k: x_j, x_k \in N(x_i)} w_{ij} G_{jk}^i w_{ik} \end{aligned} \quad (9)$$

式中, G_{jk}^i 表示 x_i 点的局部 Gram 矩阵 G^i 的第 (j, k) 项, $G_{jk}^i = (x_i - x_j)^T (x_i - x_k)$ 。由此, 每个图像点的重构权值能够用下面的 n 个标准二次规划问题解决:

$$\begin{cases} \min \sum_{j, k: x_j, x_k \in N(x_i)} w_{ij} G_{jk}^i w_{ik} \\ \text{s. t. } \sum_j w_{ij} = 1, w_{ij} \geq 0 \end{cases} \quad (10)$$

在计算出所有重构权重后, 就可以构造一个稀疏矩阵 W :

$$W(i, j) = w_{ij} \quad (11)$$

显然, W 可以作为图 G 的权重矩阵。在此构建整个图的方法是先将整个图划分成一系列的重叠线性块, 然后再将其粘贴在一起。

3.2 标签传播

假定 F 表示定义在 X 上的分类函数集, $\forall f \in F$ 能对每个 x_i 指定 f_i 的实际值, 没有标签图像点 x_u 的标签可以通过 $f_u = f(x_u)$ 决定。

在每次迭代中, 让每个图像点从它的近邻吸收标签信息的权值并保留它先前状态的一些标签信息^[9], 那么在第 $t+1$ 次迭代后 x_i 的标签为:

$$f_i^{t+1} = \alpha \sum_{j: x_j \in N(x_i)} w_{ij} f_j^t + (1-\alpha) y_i \quad (12)$$

式中, $0 < \alpha < 1$ 是 x_i 从它的近邻获得的标签信息的权值。 $y = (y_1, y_2, \dots, y_n)^T$, $y_i = Y_i (i \leq l)$, $y_u = 0 (l+1 \leq u \leq n)$, $f^t = (f_1^t, f_2^t, \dots, f_n^t)^T$ 是在 t 次迭代后的预测标签向量, $f^0 = y$, 这样可以重新将迭代方程写为:

$$f^{t+1} = \alpha W f^t + (1-\alpha) y \quad (13)$$

我们可以用此式更新每个图像点的标签, 直到稳定状态。

3.3 LANNP 算法描述

算法具体步骤如下:

Step 1 由 SVM 计算出训练样本分类面 $f(x) = 0$, 并采用欧氏距离算出在分类面上距查询点 q 最近的点 d 。

Step 2 计算出在 d 点的梯度向量 $n_d = \nabla_d f$, 求特征相关性值 $R_j(q) = |n_{dj}|$, 这里 $j = 1, 2, \dots, D$ 。估计查询点距分类面的距离, $B_q = \min_s \|q - S_s\|$, 这里 S_s 为支持向量, 并求训练点 x 与边界的近似平均距离 $H = \frac{1}{l} \sum_x \min_{s_i} \|x - s_i\|$, 求参数 $\beta = H - B_q$ 。

Step 3 利用 $r_j(q) = \frac{\exp(\beta R_j(q))}{\sum_{i=1}^D \exp(\beta R_i(q))}$ 求权值 r , 利用 D

$(x_i, x_j) = \sqrt{\sum_{k=1}^D r_k (x_{ik} - x_{jk})^2}$ 计算局部自适应距离。

Step 4 在新的距离测度下, 利用局部自适应距离 $D(x_i, x_j)$ 对每个样本点 $x_i (i = 1, 2, \dots, n)$ 计算它和其它 $n-1$ 个样本点之间的距离。根据距离的大小, 选择前 k 个与 x_i 最近的

点作为其近邻点。

Step 5 对每个 $x_i (i = 1, 2, \dots, n)$ 找到它的 k 个近邻点之后, 计算该点和它的每个近邻点之间的权重 w_{ij} , 即最小化 $\epsilon = \sum_{i=1}^n \left\| x_i - \sum_{j: x_j \in N(x_i)} w_{ij} x_j \right\|^2$, 其中 $\sum_{j=1}^n w_{ij} = 1$ 。如果 $x_j (j = 1, 2, \dots, n)$ 不是 $x_i (i = 1, 2, \dots, n)$ 的近邻, 则 $w_{ij} = 0$ 。进而求出图 G 的权重矩阵 W 。

Step 6 利用公式 $f^{t+1} = \alpha W f^t + (1-\alpha) y$ 进行迭代运算, 完成无标签数据的标注。

4 FLANNP 算法 (feedback locally adaptive nearest neighbor propagation)

FLANNP 算法是把用户每次检索结果标注的标签信息作为下次标签扩展的已知标签集, 用来对图结构重新做一些调整, 使各图像点之间的相似关系可以更接近用户的语义理解, 使得检索结果更加准确。它一方面直接从大量的未标注图像中用局部自适应距离测度的 LLE 学习方法从近邻节点提取标签信息, 另一方面利用用户提供的相关性标注来改进图结构, 因此可以得到更加准确的检索效果。

4.1 FLANNP 模型建立

FLANNP 算法就是将 LANNP 算法应用于图像检索的相关反馈机制。FLANNP 算法的模型如下:

假设 q 表示查询输入图像, $\{x_1, x_2, \dots, x_n\}$ 为图像数据库, 图像检索即为寻找一个函数 f , 使得 $f(x)$ 反映 x 与 q 之间的语义关系。通常 f 采用距离度量, 即 $f(x, q) = \text{dist}(x, q)$, 这里 $\text{dist}()$ 为距离函数。这样用户所提供的正例和负例反馈信息就可以用作训练样本。假定反馈样本集合为 $\{(x_i, y_i)\}_{i=1}^l$, 其中 y_i 为用户对 x_i 标记的标签。若 x_i 与 q 相关, 则 $y_i = 1$; 否则, $y_i = -1$ 。此时的目标就是利用该训练集进行半监督学习, 根据有标签图像和无标签图像确定函数 f , 进而预测出无标签图像的关系类别标注。为了在学习过程中有效地结合上述的无标签图像和有标签图像的信息, 我们定义了一个图 $G = (V, E)$ 。在这个图中, 节点集合 V 代表图像库中各个无标签图像和有标签图像, 而任意一个图像点 x_i 和它的近邻点 x_j 相连的边 E 为其相似性, 以权重值 w_{ij} 来量化计算。任意一个图像点通过 w_{ij} 从它近邻图像点获取标签信息, 依次循环地传递到其它图像点, 最终达到全局稳定的状态。图像点之间边的权重越大, 图像点越相似, 它们拥有相同标签的可能性就越大, 从而导出无标签图像点的标注信息。

于是, FLANNP 算法就可以看作是在构造的图上估计一个标注函数 f , 它充分结合了无标签图像点和有标签图像点的信息。为了实现全局一致性的假设, 无标签图像的标注问题最终被形式化为相关图像点类别的标签信息根据与近邻图像点的相似度在图上进行全局传递的过程。

4.2 FLANNP 算法描述

FLANNP 算法的具体步骤如下:

Step 1 使用欧氏距离度量相似性的方法进行检索, 在初始检索结果中选择 n 幅图像提供给用户, 用户标注与检索目标相关的图像, 得到用于反馈的正例集合 I_p^0 和反例集合 I_n^0 。更新集合 I_p 和 I_n : $I_p = I_p \cup I_p^0$, $I_n = I_n \cup I_n^0$, 初始化时正例和反例集合 I_p 和 I_n 都为零。

Step 2 将 I_p 和 I_n 作为已知标签信息的图像点 (x_i, y_i) ,

$x_i \in I_p \cup I_n, y_i = \begin{cases} +1, x_i \in I_p \\ -1, x_i \in I_n \end{cases}$, 由 SVM 计算出分类面 $f(x) = 0$, 并算出在分类面上距查询点 q 最近的点 d 。

Step 3 计算出在 d 点的梯度向量 $n_d = \nabla_d f$, 求特征相关性值 $R_j(q) = |n_{dj}|$, 这里 $j = 1, 2, \dots, D$ 。估计查询点距分类面的距离, $B_q = \min_{S_i} \|q - S_i\|$, 这里 S_i 为支持向量, 并求训练点 x 与边界的近似平均距离 $H = \frac{1}{l} \sum_x \min_{S_i} \|x - S_i\|$, 求参数 $\beta = H - B_q$ 。

Step 4 利用 $r_j(q) = \frac{\exp(\beta R_j(q))}{\sum_{i=1}^D \exp(\beta R_i(q))}$ 求权值 r , 利用

$$D(x_i, x_j) = \sqrt{\sum_{k=1}^D r_k (x_{ik} - x_{jk})^2}$$
 计算距离。

Step 5 在新的距离测度下, 利用局部自适应距离 $D(x_i, x_j)$ 对每个样本点 $x_i (i = 1, 2, \dots, n)$ 计算它和其它 $n - 1$ 个样本点之间的距离。根据距离的大小, 选择前 k 个与 x_i 最近的点作为其近邻点。

Step 6 对每个 $x_i (i = 1, 2, \dots, n)$ 找到它的 k 个近邻点之后, 计算该点和它的每个近邻点之间的权重 w_{ij} , 即最小化 $\epsilon = \sum_{i=1}^n \|x_i - \sum_{j: x_j \in N(x_i)} w_{ij} x_j\|^2$, 其中 $\sum_{j=1}^n w_{ij} = 1$ 。如果 $x_j (j = 1, 2, \dots, n)$ 不是 $x_i (i = 1, 2, \dots, n)$ 的近邻, 则 $w_{ij} = 0$ 。进而求出图 G 的权重矩阵 W 。

Step 7 利用公式 $f^{t+1} = \alpha W f^t + (1 - \alpha) y$ 进行迭代运算, 完成无标签数据的标注。使任意图像点从其相邻图像点获取标签信息, 对具有正例的图像点计算其与查询输入图像点 q 的距离, 将距离最近的前 n 幅图像反馈给用户。如果正例的图像数少于 n 幅, 就从反例图像中选取与查询图像距离最近的, 补足剩余的图像。

Step 8 用户对反馈的图像重新进行标注, 得到用于反馈的正例集合 I_p^1 和反例集合 I_n^1 , 以此再进行集合 I_p 和 I_n 的更新, $I_p = I_p \cup I_p^1, I_n = I_n \cup I_n^1$ 。

Step 9 转到 Step 2, 对新的有标签信息重新进行标签扩展, 并继续进行检索, 直到找到足够数量的相似图像或者相似图像数目不再增加为止。

上述算法的 Step 8 确保了有标签的图像点不会随着标签的全局传递而改变。因为在每一轮标签传递的循环中, 初始标签信息都会在 Step 8 被强制填回, 参与下一轮的标签传递。事实上, 我们只关心正例标签图像点的标注。

5 实验与分析

5.1 人工数据的可视化实验

双螺旋线分类一直是模式识别领域公认的一个相当有难度的问题。一般的线性分类器对它只能有 50% 左右的分辨率, 而三螺旋线的分类就更有难度了, 它们也因其难度而经常被用作检验模式识别算法性能的试金石^[10]。为验证本文提出的 LANNP 算法的有效性, 对三螺旋线进行标记实验。实验中所用参数 $\alpha = 0.99, k = 13$, SVM 采用高斯径向基核函数, 其参数 $\sigma = 3$, 结果如图 2 所示。

原始的数据点每条螺旋线为 400 个点, 先将其作为两类, 将一条单独作为一类, 用红色圆圈标记出 20 个点作为其已知

标签点。将其它两条作为一类, 每条用绿色圆圈标记出的 10 个点为其已知标签点, 如图 2(a) 所示。然后, 用 LANNP 算法进行两类标签扩散实验, 标记出其它未知标签点, 其结果如图 2(b) 所示。蓝色圆为一类, 红色“+”为另一类。将红色“+”号的两条螺旋线分别看作一类, 用同样的方法进一步分类, 其结果如图 2(c)、图 2(d) 所示。由图 2 可以看出, LANNP 算法分类能力比较强大。

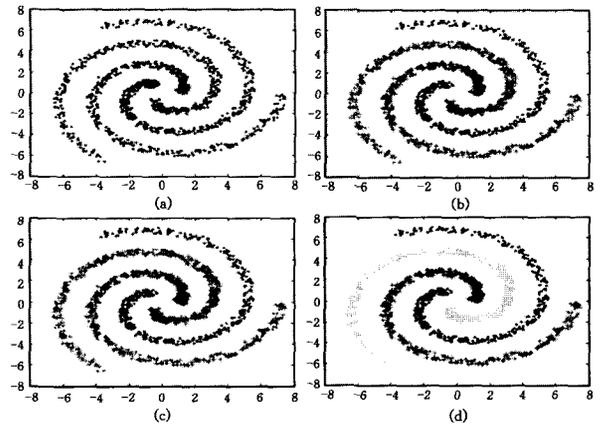


图 2 三螺旋线分类效果

5.2 自然图像检索实验

通过几个对比实验, 说明了我们所提出的 FLANNP 算法的有效性。

5.2.1 图像特征

为验证本文提出的反馈算法的优越性, 用表 1 所列的 400 维图像低层特征进行检索实验, 它包含了颜色、纹理和形状信息。

表 1 实验中所用的图像特征

特征名称	维数
颜色直方图 ^[11]	256
颜色矩 ^[12]	9
边缘直方图 ^[11]	5
contourlet 变换纹理 ^[13]	62
边缘方向直方图 ^[14]	68
总计	400

5.2.2 算法性能检验

Corel 图像库广泛使用在基于内容的图像检索系统。为了便于评价, 我们就选择这个图像集用于测试实验。凭经验选择 30 个语义类的彩色图像, 包括大象、雪山、鸟、海浪、汽车、花等, 每个语义类由 100 幅图像组成。实验中, FLANNP 采用高斯径向基核函数, 其参数 $\sigma = 3$ 。参数 α 取 0.99, k 取 8; FSVM (以 SVM 作为相关反馈机制) 采用高斯径向基核函数, 其参数 $\sigma = 3$; FLNP (以 LNP 作为相关反馈机制) 参数 α 取 0.99, k 取 7。本文使用查准率 (Precision) 来评价图像检索系统的检索性能, 其定义如下:

$$precision = \frac{A}{A+B} \quad (11)$$

式中, A 为检索出的正例图像, B 为检索出的负例图像。

实验一 实际上要求用户提供多轮反馈是不现实的, 前两次的检索性能是最重要的。为显示本文方法的反馈效果, 用 SVM 和 LNP (详见文献[8]) 作为反馈机制 (即 FSVM 和 FLNP) 与之相比较, 分别对各类图像做两次反馈, 并分别计

算出两次反馈后的前 36 幅图的各类平均查准率,作出精度曲线进行比较,如图 3 所示。

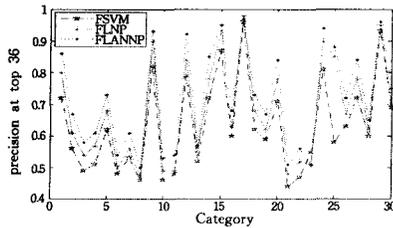


图 3 第二次反馈后 3 种算法的前 36 幅的查准率

从图中可以看出:3 种相关反馈检索方法的性能随着种类的不同有所变化,FLANNP 和 FLNP 都比 FSVM 查准率高,FLANNP 总体上比 FLNP 性能要好。

实验二 为分析对比 FSVM、FLNP 和 FLANNP 3 种算法对不同反馈次数的性能变化,我们对取前 25 幅和 36 幅图时 4 次反馈的查准率进行比较实验,其结果如图 4 所示。

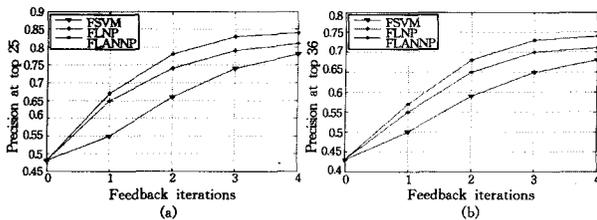


图 4 取前 25 幅和 36 幅图时 3 种算法查准率

图 4 显示出,通过迭代加入用户的反馈取前 25 和 36 幅图时相应的查准率,图中开始点为没有反馈信息的原始检索结果,可以看出用户进行前两轮相关反馈后,其检索精度有大幅度的提高。此后,检索精度的提升则渐趋平缓。我们提出的算法在总体范围上要优于 FLNP 和 FSVM 两种方法。3 种方法都明显优于无反馈算法,这显示出用户提供的相关反馈信息对于提高检索性能是非常有益的。随着反馈次数增加,能够发掘出更多的相关图像,反馈机制可以明显地提高查准率。实验结果证明了这一点。

5.2.3 实验总结

从以上的实验结果可以看出,当有标签的图像点不足时,FLANNP 和 FLNP 算法都取得了比 FSVM 方法更好的性能。其原因主要是:这两种方法都可以充分利用图的结构来平滑未知标签图像点的标签信息,因而未知标签图像点的标签信息不仅由附近的有标签图像点决定,而且由附近的未知标签图像点决定。而对于有监督的学习方法 FSVM 算法,太少的有标签图像点不足以揭示关系类别的分类边界,而它又无法借助于未知标签图像点的信息来发现结构信息,所以无法相对准确地学习出分类超平面,从而导致运行的效果不佳。本文算法在构建图时,将鉴别信息引入到 LANNP 算法中,由支持向量机构建的判别函数来确定最优判别方向,利用样本的分类信息在高维空间的某个邻域内学习一个合适距离测度,使得在这个测度意义下类内凝聚、类间散布。使用此具有鉴别信息的距离测度来代替欧式距离测度,充分利用先验知识,尽量增大源数据中的有效信息量。所以,我们提出的 FLANNP 方法在图像检索中能获得更好的结果。

结束语 本文的特色就是使用有鉴别信息的距离测度来代替欧式距离测度,将先验鉴别信息引入到 k -近邻块中。并

利用无标签图像点信息半监督学习各图像点间的相关性,解决有标签图像点不足的问题,主要有以下 3 个方面:

(1)使用有鉴别信息的距离测度来代替欧式距离测度计算 k -近邻,将先验鉴别信息引入到 k -近邻块中,增大不同类间的间隔,提高流形学习的泛化能力。

(2)提出用图策略来建立图像库中各图像点间的相关性模型。当有标签图像点不足时,依靠无标签图像点的信息能够尽可能准确地挖掘出图结构内部所潜在的信息来辅助检索的实现。

(3)充分利用建立的相关性图模型,利用半监督学习的标签传递算法在该模型上进行标签的全局传递,实现全局一致性的目标,提高图像检索的准确度。

参考文献

- [1] Chapelle O, Schölkopf B, Zien A. Semi-supervised Learning[M]. MIT Press, 2006
- [2] Dempster A P, Laird N M, Rubin D B. Maximum likelihood from incomplete data via the EM algorithm[J]. Journal of the Royal Statistical Society, 2000, 39(1): 1-3
- [3] Blum A, Mitchell T. Combining labeled and unlabeled data with co-training[C]//Proceedings of the 11th Annual Conference on Computational Learning Theory. 1998: 92-100
- [4] Zhou Z H, Li M. Tri-training: exploiting unlabeled data using three classifiers[J]. IEEE Transactions on Knowledge and Data Engineering, 2005, 17(11): 1529-1541
- [5] El-Yaniv R, Pechyony D, Vapnik V. Large margin vs large volume in transductive learning[J]. Machine Learning, 2008, 72(3): 173-188
- [6] Zhou Z-H, Chen K-J, Dai H-B. Enhancing relevance feedback in image retrieval using unlabeled data[J]. ACM Transactions on Information Systems, 2006, 24(2): 219-244
- [7] Amari S, Wu S. Improving support vector machine classifiers by modifying kernel functions[J]. Neural Netw, 1999, 12: 783-789
- [8] Wang Fei, Zhang Changshui. Label Propagation Through Linear Neighborhoods[J]. Knowledge and Data Engineering, IEEE Transactions on, 2008, 20(1): 55-67
- [9] Zhu X, Ghahramani Z. Learning from Labeled and Unlabeled Data with Label Propagation[R]. CMU-CALD-02-107. Carnegie Mellon Univ., 2002
- [10] 吴今培, 孙德山. 现代数据分析[M]. 北京: 机械工业出版社, 2006
- [11] Manjunath B S, Ohm J-R, Vasudevan V V, et al. Color and Texture Descriptors[J]. Circuits and Systems for Video Technology. IEEE Transactions on, 2001, 11(6): 703-715
- [12] Stricker M A, Orengo M. Similarity of color images [C]// Storage and Retrieval for Image and Video Databases (SPIE). 1995: 381-392
- [13] 黄传波, 邵杰, 万鸣华, 等. Contourlet 变换在图像检索中的应用[J]. 计算机工程与应用, 2009, 45(3): 24-27
- [14] Pinheiro A M G. Image Description Using Scale-Space Edge Pixel Directions Histogram[A]// Second International Workshop on Semantic Media Adaptation and Personalization[C]. Dec. 2007: 211-218
- [15] 牛盼盼, 王向阳, 周璐, 等. 基于多语义特征的彩色图像检索技术研究[J]. 计算机科学, 2009, 36(3): 26-231