

DOI: 10.7652/xjtuxb201304016

采用改进的尺度不变特征转换及多视角模型对车型识别

华莉琴, 许维, 王拓, 马瑞芳, 胥博

(西安交通大学系统工程研究所, 710049, 西安)

摘要: 针对车型识别过程中车辆的姿态复杂以及采集图像时尺度缩放和光照等因素导致识别出现困难的问题, 提出采用改进尺度不变特征转换(SIFT)及多视角的车型识别算法。该算法对尺度不变特征提取方法进行改进, 并获取车型特征; 通过视觉聚类对车辆进行多视角建模; 利用最佳节点优先搜索算法完成特征向量的近邻搜索, 并根据匹配相似度完成车型识别。实验结果表明, 该算法所给出的车型识别方法具有可行性和有效性, 可以在不同的图像畸变条件下保持稳定, 最终的车型识别效率也都可达到 90%, 所用时间要低于 SIFT 方法, 处理时间在原 SIFT 方法的基础上降低了 20.58%。

关键词: 车型识别; 改进尺度不变特征转换; 最佳节点优先搜索算法; 多视角建模

中图分类号: TP391 **文献标志码:** A **文章编号:** 0253-987X(2013)04-0092-08

Vehicle Recognition Using Improved SIFT and Multi-View Model

HUA Liqin, XU Wei, WANG Tuo, MA Ruifang, XU Bo

(Systems Engineering Institute, Xi'an Jiaotong University, Xi'an 710049, China)

Abstract: A method to recognize vehicles using an improved SIFT and multi-view model is proposed to improve the recognition problem caused by the complex posture of vehicle, scale zoom and illumination. The SIFT algorithm is improved to capture the feature of vehicles; the multi-view model of vehicles is built through visual clustering; The BBF algorithm is used to complete the nearest neighbor search of feature vectors, and vehicles are recognized by similarity matching. Experiments show that the proposed method of vehicle recognition is feasible and effective, and the method can keep stability in different conditions of image distortion. The rate of recognition can be up to 90%, the time is lower, and the processing time is reduced by 20.58% based on the original SIFT method.

Keywords: vehicle recognition; improved scale-invariant feature transform; best bin first; multi-view model

随着我国经济的快速发展, 汽车数量正在持续快速增加, 而道路设施与汽车数量高速增长的矛盾显现, 交通拥挤严重影响人们的出行, 多发的交通事故进一步加剧交通拥挤。为此, 本文提出利用图像理论及计算机视觉技术快速对车型进行识别, 进而对交通事故智能识别, 主动报警, 并为进一步对交通

事故责任的认定提供技术支持。车辆在发生事故后, 会呈现不同的车辆姿态。如何在这样的背景下识别出车辆的类型、车辆的特征模型及特征获取是解决问题的关键。

目前, 基于计算机视觉的车型识别方法有 3 类:
①基于特征匹配的车型识别方法, 通过提取图像的

收稿日期: 2012-06-11。 作者简介: 华莉琴(1987—), 女, 硕士生; 王拓(通信作者), 男, 教授, 博士生导师。 基金项目: 国家自然科学基金资助项目(61071217)。

网络出版时间: 2013-02-19

网络出版地址: <http://www.cnki.net/kcms/detail/61.1069.T.20130219.1010.006.html>

颜色、纹理、形状等特征来进行车型的识别工作,但成像视角转变后识别效率下降;②基于模型匹配的车型识别方法,建立车辆的三维模型或者车辆组成部分的模型,但是提取难度大,计算较复杂;③基于分类器的车型识别方法,一般需要对较多样本进行训练。

为此,本文提出基于改进 SIFT(Scale-invariant feature transform,尺度不变特征转换)特征及多视角模型的识别方法:一方面对 SIFT 算法高维度问题进行改进,用改进后的 SIFT 算法提取车辆的特征;另一方面,采用视觉聚类法进行车辆特征建模和识别,即使用图像采集设备围绕车辆目标进行多视角图像采集,再根据相关的聚合算法来完成某车型模型的建立,既避开了复杂的三维建模,又能很好地满足实时性要求。车型识别的基本过程如图 1 所示。




图 1 车型识别的基本过程

1 改进 SIFT 算法及车辆特征提取

因车辆姿态及外界环境比较复杂,要求提取车辆特征的算法应具有旋转、尺度缩放和视角不变的特性。虽然 SIFT 算法具备旋转、尺度缩放和光照不变性^[1-2],但其维数过高,运算复杂,故现对其维数过高问题进行改进。

1.1 SIFT 算法介绍

在进行车辆特征提取时,首先利用高斯函数建立车辆图像的尺度空间,以达到尺度不变性的目的。差分高斯尺度空间^[3]的构建过程和车辆图像的高斯尺度空间表达结果分别如图 2、图 3 所示。

通过比较当前和上下相邻尺度图像的 26 个像素点来确定特征点,同时剔除低对比度和边缘上的特征点^[4],来提高后续识别的稳定性和抗噪能力。

SIFT 算法的描述过程如下:①根据特征点的主方向旋转图像的坐标轴;②用一个具有参数 σ 的高斯权重函数来为每个样本特征点梯度值赋一个权重;③在每个子区域中的 8 个梯度方向上,累加加权




图 2 差分高斯尺度空间



图 3 车辆图像高斯尺度空间表达结果

之后的梯度模值,最终生成的特征向量为 128(4×4×8)维,如图 4 所示;④对特征向量进行归一化。




图 4 特征向量描述符

SIFT 特征提取算法联合特征点的邻域像素信息,提高了特征的可区分性,但是对于特征向量的识别,需要搜索其 K 最近邻。由于特征向量维度普遍过高,故在超过某一额度时传统的多维搜索技术的检索效率低下,这极大地损害了特征识别的实时性,也就是产生了“维度灾难”。

1.2 改进 SIFT 特征描述

本文在保证不丢失特征信息的前提下,吸取了文献[5]中的圆形划分思想,并结合向量之间的排序方法对 SIFT 多维特征向量进行了降维改进。以特征点为中心,选取圆形邻域做同心圆划分,统计每一层同心圆的梯度方向值,形成降维后的特征向量。

新的圆形邻域描述方法具体步骤如下。

步骤1 以特征点为中心形成8个同心圆环,如图5所示。为了与之前方形邻域的划分范围保持一致,取邻域半径为 8×8 。




图5 改进的向量描述符

步骤2 在每个同心圆范围内统计其8个方向($0^\circ, 45^\circ, 90^\circ, 135^\circ, 180^\circ, 225^\circ, 270^\circ, 315^\circ$)的梯度加权模值的累加值。由内至外按顺序分别选取环形区域的8维向量形成最终特征向量,即取第1个圆环内的8维向量为特征向量的前8个元素,第2个圆环内的8维向量作为第9到第16个元素,以此类推,最终的圆形特征向量为 $64(8 \times 8)$ 维向量。

步骤3 为达到旋转不变性的目的,对不同环内的特征向量实施排序操作。假设 C_i 是以特征点为中心的第 i 个圆环所形成的向量, $C_i = \{m_{i1}, m_{i2}, m_{i3}, \dots, m_{i7}, m_{i8}\}$, m_{ij} 表示环内8个方向的加权梯度模值, $i \in [1, 8], j \in [1, 8]$ 。 $C = \{C_1, C_2, C_3, \dots, C_7, C_8\}$, C 为最终生成的特征向量。按照从大到小的顺序对每一个 C_j 进行排序,按序形成最终的特征向量。排序后的特征向量保证了旋转后的特征点邻域的特征向量总是按相同的顺序产生,从而可达到旋转不变性的目的。根据不同的匹配需要,可进一步对排序后的特征向量进行采样形成新的特征向量,但由于邻域信息的减少,匹配稳定度会受到影响。

步骤4 为减少线性光照改变的影响,对最终形成的特征向量进行尺度归一化处理

$$\bar{C} = C / \left(\sum_{i=1}^{i=64} m_i^2 \right)^{1/2} = (\bar{m}_1, \bar{m}_2, \bar{m}_3, \dots, \bar{m}_{63}, \bar{m}_{64}) \quad (1)$$

1.3 改进后的SIFT降维实验

对同一车辆特征点进行实验,得到同一个尺度下改进前后的向量描述子,改进后的向量维数从128维降为64维,且8个子集中的元素是有序的。

改进后的特征描述符有如下两个优势:①因圆形本身就是具有旋转不变性的,也就不需要计算主

方向和坐标对齐的步骤,从而克服了矩形领域划分法的不足;②根据邻域像素距离特征点的远近,在梯度模值的计算上使用了高斯加权,而高斯加权的等高线就是以特征点像素位置为中心的呈高斯分布的同心圆。采用圆形邻域划分后,高斯加权和特征向量的计算可同步进行。

2 多视角车型识别

利用上述方法可获得车辆图像的多维特征向量,与通过视觉聚类对车辆多视角建模所得的特征向量进行匹配、分析,最终完成车型的识别。

2.1 特征匹配

本文采用传统的欧式距离^[6]度量算法进行向量匹配,特征点间的距离为

$$S = \left(\sum_{i=1}^{i=64} (X_i - Y_i)^2 \right)^{1/2} \quad (2)$$

式中: X_i, Y_i 为点的特征描述元素,当距离 S 最小时,它们最有可能是匹配点对。在不同的特征点集中搜寻距离最小的点,成为一个最近邻搜索的问题。

由于特征点数量众多且均为高维特征向量,我们利用索引树对向量的多维空间进行划分后,再在特征点集上搜寻最近邻。 k -d树(k -dimension tree)又称为多维二进制搜索树,是在 k 维空间中对数据点进行划分的一种高效数据结构^[7]。 k -d树的每个节点包括两个指针,或者为空,或者指向另一个子树节点。此外,每一个节点还要存储一个指示器,是0到 $k-1$ 之间的整数。假设节点 p 的 k 个维为 $K_0(p), K_1(p), K_2(p), \dots, K_{k-1}(p)$,左子树指针为LowSon(p),右子树指针为HighSon(p),指示器计为DISC(p),则 k -d树的构建如下:对于 k -d树中的任一节点 P ,假设DISC(P)为 j ,对于LowSon(P)中的任何节点 Q ,总有 $K_j(Q) < K_j(P)$;对于HighSon(P)中的任何节点 R ,总有 $K_j(R) > K_j(P)$ 。

下面的算法为在 k -d树中搜索一个特定的记录。假定传入的参数为节点 P ,它的LowSon、HighSon、DISC域都没有设置。如果 P 在树中,算法返回 P 的指针,否则算法返回值为空并且把 P 插入到树中。其中,函数ValofD(val, k)指的是val第 k 维的值。

KDNode * KdSearch (KDNode * node, Value val, int h, int dimension) {

//node为开始搜索的节点,val为要搜索节点的多维值

```
// h 为节点处于的深度, dimension 为 k-d 树的维数
if (node == NULL) return NULL; // 无法找到该节点
else if (val == node->val)
    return n; // n 即是搜索的节点
else {
    int k = h mod dimension; // 求得识别器的编号
    if (ValofD(val, k) < ValofD (node->value, k))
        return KdSearch (node->left, val, h + 1, dimension); // 小于识别器, 在左子树
    else return KdSearch (node->right, val, h + 1, dimension); // 大于识别器, 在右子树
}
```

由以上搜索过程可以看出, k -d 树对最近邻的查询本质是路径的不断“回溯”, 在决定是否要回溯时仅依赖于查询路径。如果能够将查询路径上的节点按分割超平面与查询点的距离排序, 并用优先队列记录当前节点和被查询点之间距离最近的节点信息, 回溯检查从优先级最高的树节点开始, 并设置运行超时限定, 当优先级队列中所有的节点都经过检查或者超出时间限制时, 返回当前找到的最好结果作为近似的最近邻。据此思想, 对 k -d 树进行一个最佳节点优先 (Best Bin First, BBF) 改进。BBF 算法实现的流程图如图 6 所示, 具体步骤如下。




图 6 特征向量的近邻搜索流程图

- 步骤 1** 构建优先队列 prio-queue 和存放 K 个最近邻特征点的队列 nbrs。
- 步骤 2** 初始化优先队列 prio-queue。 k -d 树根结点先入队列; prio-queue 里面存放的是即将进行遍历

的节点, 根据每个节点分类器的关键字与被搜索特征点的欧式距离的递增顺序进行排列, nbrs 为空。

步骤 3 从优先队列里依次提取节点进行遍历。若为叶子节点, 就按照与被搜索的特征点的欧式距离进入最近邻点队列, 否则, 根据分类器的值来决定遍历的范围; 另一个落选的还未进行遍历的节点 (子树) 根据优先队列的排列规则进入优先队列。

步骤 4 当优先队列 prio-queue 不为空且所遍历的结点总数未达到最大值 max-nn-chks 时, 重复步骤 3。

BBF 算法虽然要构建 k -d 树, 但是在模型库已经建立好的情况下, 特征点集的 k -d 树是可以提前离线构建的。在特征点集规模很大的时候, BBF 总是从优先级最高的节点开始, 同时还设置了运行超时限定, 其搜索时间远远小于穷尽搜索。

2.2 特征提纯

在实际的特征匹配过程中, 如果在其中某一特征向量集合中不存在和相应特征向量很相似的特征向量, BBF 算法仍能找到最近邻, 属于典型的误识别。由于背景模糊或是有的点根本就不存在匹配点, 极易导致此类误匹配情况的发生, 必须剔除。

将 1 近邻搜索进行一个简单的 K 近邻扩展^[8], 利用 K 近邻特征向量的信息对 1 近邻搜索到的特征向量进行约束, 就可以达到相似性提纯的目的。考虑到复杂度的影响, 取 $K=2$, 即同时搜索特征向量的最近邻以及次近邻。引入最近邻和次近邻距离的比值 R 。若对相似图像目标进行最近邻及次近邻搜索, R 应该分布于 $[0, 1]$ 区间的中间部分, 而对完全不同的图像目标进行最近邻和次近邻搜索, 由于两幅图像目标间的差异巨大, 特征向量的最近邻和次近邻在特定情况下会无限接近, 而在其他情况下又可能相差极大, 则 R 分布于区间两端。

通过实验, 对 40 000 多组特征向量 R 的分布进行统计。当 R 位于 $0.35 \sim 0.46$ 之间时, 特征向量的相似度最高, 在 0.45 附近达到峰值, 而当 R 高于 0.75 时, 特征向量的相似度最低, 且误识率很高。

图 7 为 R 在 0.7 和 0.5 时的特征向量匹配结果。明显可见: 当 R 取到 0.7 时, 出现了误匹配; 当 R 在 0.5 时, 误匹配得到了消除。

2.3 多视角建模

目前, 大部分识别算法只能从某一特定角度去识别车型, 无法识别姿态不可预知的车辆。本文通过视觉聚类算法进行车辆多视角建模, 将三维空间划分为若干个区域, 每个区域代表一类视角, 如图 8



(a) $R=0.7$ 的匹配结果(b) $R=0.5$ 的匹配结果

图7 不同比例阈值下特征向量的匹配结果

所示。在车辆的斜上方进行拍摄,并以车辆为圆心,在水平面按照一定角度旋转移动相机,直到相机环绕车体一周为止,其中 α 为摄像头俯角, β 为水平移动角度。本文着重研究水平移动角度 β ,取 $\alpha=0^\circ$ 。




图8 多视角建模

若对每一类车型都进行 360° 范围内的小角度均匀密集采样,虽然能保证车型的正确识别,但极大地增加了前期建模的工作量和难度,不同的采样角度之间必然会存在相似度极高的冗余特征点,严重影响识别算法的实时性。为此,在对车辆进行视觉聚类建模的过程中,需要着重解决采样角度的选择和冗余特征点的剔除准则问题。

2.3.1 采样角度选择 特征随视角改变而发生的变化是依赖于特征描述子的抗视角变化性。改进SIFT特征提取算法得到的车辆特征在有限的视角范围内,对提取到的车辆特征可以保证实现正确的匹配,但随着视角的不断增加,特征点之间差异性不断增大,匹配效率也逐渐下降。根据文献[9]的结论,当视角变化超过 35° 时,特征不变性基本无法保证。本文通过在不同角度下对特征的匹配稳定性进

行统计,得到了随着角度的增加改进SIFT特征提取算法提取到的特征的视角稳定性,如图9所示。由以上理论及实验结果可知,视角的采样间隔不应该超过 25° ,本文以 20° 为基准采样角度对车辆进行多视角间隔采样。




图9 不同视角下特征向量的匹配稳定性

2.3.2 冗余点剔除 在确定采样间隔角度后,就要确定聚类冗余特征点的剔除原则。根据坐标变换原理,假设 $[x, y]^T$ 为聚类模型中的某一特征点, $[u, v]^T$ 为待匹配图像中的另一特征点,它们之间的关系可表示为

$$\begin{bmatrix} u \\ v \end{bmatrix} = \begin{bmatrix} s \cos \theta & -s \sin \theta \\ s \sin \theta & s \cos \theta \end{bmatrix} \begin{bmatrix} x \\ y \end{bmatrix} + \begin{bmatrix} t_x \\ t_y \end{bmatrix} \quad (3)$$

式中: $[t_x, t_y]^T$ 表示平移量。假设 $m = s \cos \theta, n = s \sin \theta$,对式(3)进行变换后可得

$$\begin{bmatrix} u \\ v \end{bmatrix} = \begin{bmatrix} m & -n \\ n & m \end{bmatrix} \begin{bmatrix} x \\ y \end{bmatrix} + \begin{bmatrix} t_x \\ t_y \end{bmatrix} \quad (4)$$

进一步变换为

$$\begin{bmatrix} x & -y & 1 & 0 \\ y & x & 0 & 1 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} m \\ n \\ t_x \\ t_y \end{bmatrix} = \begin{bmatrix} u \\ v \\ 0 \\ 0 \end{bmatrix} \quad (5)$$

式(5)显示了一个点对应关系方程,其中只包括了一个匹配点对,如果有更多的对应点对存在,可以依次添加至行列式末尾。对式(5)做进一步变化

$$\mathbf{AX} = \mathbf{b} \quad (6)$$

根据不同匹配特征点的坐标,利用最小二乘法求解式(6)中的 $\mathbf{X}$,可求得 $\mathbf{X}$ 的解

$$\mathbf{X} = [\mathbf{A}^T \mathbf{A}]^{-1} \mathbf{A}^T \mathbf{b} \quad (7)$$

2.3.3 车辆三维模型建立 以18幅二维图像依次作为训练图像,对每一幅图像都用改进SIFT算法提取特征点,并以特征向量的形式进行描述。其中第1幅图像作为多视角车辆信息的初始模型,可以对 20° 视角范围内的车辆特征进行匹配识别。当训练图像到达后,先与初始模型中的特征点进行匹配,

计算训练图像和初始模型之间的空间坐标变换参数,同时引入误差度量函数 $E=(2\parallel \mathbf{AX}-\mathbf{b}\parallel^2/(r-4))^{1/2}$,其中 r 表示矩阵 $\mathbf{A}$ 中的行数。给定阈值参数 T , T 取 0.05 倍的图像最大分辨率,计算训练图像和初始模型所匹配的特征点的误差 E ,并同阈值参数 T 比较,共有如下 3 种情况:①训练图像和初始模型并未找到匹配的特征点,表明训练图像和初始模型的角度相差过大或不属于同一类目标,需建立新的对象模型进行描述;②训练图像和初始模型存在匹配的特征点,并且匹配点的误差 $E>T$ 时,表示此类特征点与初始模型中的特征点存在角度差异,其自身所携带的车辆信息有别于原模型车型信息,此类特征点需要进行保留,并更新原始车型特征模型库;③训练图像和初始模型存在匹配的特征点,且 $E\leq T$,表示此类特征点和原有特征点之间的角度特征相似度过高,属于冗余特征点,需要剔除。

通过对训练图像经过如上所述的不断聚类,多幅任意角度的车辆图片信息将最终建成一个多角度的车型模型库,就可用于车型的多视角识别。

2.4 车型识别

车辆特征提取的最终目的是为了车型识别,为此引入特征相似度概念

$$R_p = P_{\text{correct}}/P_{\text{sum}} \times 100\% \tag{8}$$

式中: R_p 表示特征相似度; P_{correct} 表示在车辆匹配过程中所正确匹配到的特征点数量; P_{sum} 表示基准车型库中特定车型的特征点数目。由于 SIFT 特征联合了特征点的邻域像素信息,所得到的车辆特征向量高度独立,具有可区分性,同类车型的特征向量之间的相似度远远高于不同车型所提取到的特征向量。可以使用如下准则^[10]来判别某车辆是否属于某车型:①总匹配特征数大于等于 m ;②相似度大于等于 a 。满足以上任意一个条件,就可以判定待识别车辆属于该车型。其中, m 和 a 的取值需要视车型识别系统的其他参数而设定。


3 实验结果及分析

本文选取了常见车型中的小轿车、越野车、面包车及大巴车 4 类车型进行验证。样本图像为来自 UIUC 大学^[11]车型识别库中的 100 张图像和采集的 460 张其他车型的图片,对其中 455 幅图片进行训练,105 幅图像进行测试。本文主要从识别时间及识别率对车型识别算法进行评定: ①识别时间


$T=T_{\text{in}}-T_{\text{out}}$,其中 T_{in} 为待识别车辆输入时刻, T_{out} 为识别结果输出时刻;②识别率 $R_s=N_{\text{correct}}/N_{\text{sum}}\times 100\%$, N_{correct} 表示正确识别的特定车型的图像数量, N_{sum} 表示特定车型在特定图像畸变条件下的样本图像总量。

3.1 不同条件下的识别结果


(1)旋转条件下的识别结果。图 10 为旋转变换条件下,不同车辆与其在车型数据库所搜寻到的特征相似度最高的基准车型图像之间的匹配点的连线。表 1 为改进前后旋转变换车型识别所耗费的平均时间及识别率。可以看出,本文算法对车辆图像的旋转有较好的适应性。




(a)小轿车



(b)越野车



(c)面包车




(d)大巴车

图 10 旋转条件下的车型识别结果

表 1 在旋转变换下的车型识别效果

车型	平均耗费时间/s		平均识别率/%	
	改进前	改进后	改进前	改进后
小轿车	8.13	6.17	93.12	92.26
越野车	8.41	6.04	92.15	91.57
面包车	9.67	7.52	93.04	92.80
大巴车	10.05	8.13	93.67	93.06


(2)缩放变换下的识别结果。图 11 为在缩放变换条件下,不同外形的车辆与其在车型数据库所搜寻到的特征相似度最高的基准车型图像之间的匹配点的连线。表 2 表示了改进前后在缩放变换下对不同车型进行识别所耗费的平均时间及平均识别率。




(a)小轿车



(b)越野车



(c)面包车



(d)大巴车

图 11 缩放变换下的车型识别结果

表 2 在缩放变换下的车型识别效果

车型	平均耗费时间/s		平均识别率/%	
	改进前	改进后	改进前	改进后
小轿车	8.21	6.51	92.51	91.38
越野车	8.06	7.02	91.98	91.53
面包车	9.21	7.86	93.03	92.36
大巴车	9.93	8.39	93.11	92.41

可以看出,在缩放变换下算法对各种车型的识别率维持在 91%左右,通过尺度参数来实现尺度无关性是在离散状态下对原有连续尺度空间的模拟,不可能完全表示出所有尺度层,因此在缩放变换的条件下,其识别率比旋转变换下略低。

(3)光照变换下的识别结果。表 3 表示了改进前后在不同光照条件下对不同车型进行识别所耗费的平均时间及平均识别率。可以看出,在不同的光照变换下,算法对各种车型的识别率维持在 90%左右,算法对特征向量的描述依赖于梯度模值和方向,而梯度模值和方向是依赖于光照的,受光照影响识别率有所波动。

表 3 在光照变换下的车型识别效果

车型	平均耗费时间/s		平均识别率/%	
	改进前	改进后	改进前	改进后
小轿车	8.54	6.34	91.67	90.79
越野车	8.32	6.50	91.84	90.85
面包车	9.48	7.85	92.21	91.18
大巴车	9.86	8.09	93.02	91.70

(4)噪声干扰状况下的识别结果。表 4 为改进前后校验噪声下对不同车型识别所耗费的平均时间及平均识别率。可以看出,在不同的噪声影响下,对各种车型的识别率维持在 90%左右,由于本文算法以点特征对车辆特征进行描述,依赖于特征点的像素及方向,而校验噪声点对特征点定位及识别存在较大干扰,因此影响了最终识别效率。

表 4 在噪声条件下的车型识别效果

车型	平均耗费时间/s		平均识别率/%	
	改进前	改进后	改进前	改进后
小轿车	8.54	6.34	91.67	90.79
越野车	8.32	6.50	91.84	90.85
面包车	9.48	7.85	92.21	91.18
大巴车	9.86	8.09	93.02	91.70

3.2 实验结果的对比分析

综合以上 4 种不同类型的识别实验结果,可以算出在不同畸变条件下,小轿车、越野车、面包车以及大巴车的平均耗费时间及平均识别率如表 5 所示。可见本文算法可以在不同的图像畸变条件下保持稳定性,最终的车型识别效率也都可达到 90%,所用时间要低于 SIFT 方法,处理时间在原 SIFT 方法的基础上降低了 20.58%。

表 5 在不同畸变条件下的车型识别效果

车型	平均耗费时间/s		平均识别率/%	
	改进前	改进后	改进前	改进后
小轿车	8.27	6.58	92.41	91.14
越野车	8.13	6.98	91.73	90.97
面包车	9.35	8.04	92.59	91.88
大巴车	10.11	8.44	93.24	92.11

4 结 论

本文针对不同姿态的车型识别问题,提出了一种基于改进 SIFT 算法及多视角建模的识别方法。通过选取大量实验样本图像进行实验验证可以看出,本文的方法在一定程度上提高了车型识别的鲁棒性与不同条件下的适应性,以及实时性的要求。通过对不同车型在不同图像畸变条件下的平均识别时间及识别率的统计分析,也证明了本文算法的可行性和车型识别的有效性。该方法不仅在车型识别的实用性以及通用性上有所提高,同时也为车型识别的难题提出了一个新的解决思路,为交通事故自动检测提供了重要的理论依据,具有实际应用价值。

参考文献:

[1] LOWE D G. Distinctive image features from scale-invariant key points [J]. International Journal of Computer Vision, 2004, 60(2): 91-110.

[2] LOWE D G. Object recognition from local scale invariant features [C] // Proceedings of the International Conference on Computer Vision. Piscataway, NJ, USA: IEEE Computer Society, 1999: 1150-1157.

[3] CROWLEY J L. A representation for visual information [D]. Pittsburgh, USA: Carnegie Mellon University, 1981.

[4] 刘星毅, 韦小铃. 基于欧式距离的最近邻改进算法 [J]. 广西科学院学报, 2010, 26(4): 409-411.

LIU Xingyi, WEI Xiaoling. Improved kNN algorithm based on Euclidean distance [J]. Journal of Guangxi

Academy of Sciences, 2010, 26(4): 409-411.

[5] MIKOLAJCZYK K. A performance evaluation of local descriptors [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2005, 27(10): 1615-1630.

[6] XIANG Shiming, NIE Fiping. Learning a Malanobis distance metric for data clustering and classification [J]. Pattern Recognition, 2008, 41(12): 3600-3612.

[7] LI Baihua, HORST H. Using *k*-d trees for robust 3D point pattern matching [C] // Proceedings of the 4th International Conference on 3D Digital Imaging and Modeling. Piscataway, NJ, USA: IEEE Computer Society, 2003: 95-102.

[8] 娄震, 金忠, 杨静宇. 基于类条件置信变换的后验概率估计方法 [J]. 计算机学报, 2005, 28(1): 18-24.

LOU Zhen, JIN Zhong, YANG Jingyu. A novel approach to estimate posterior probabilities by class-conditional confidence transformations [J]. Chinese Journal of Computers, 2005, 28(1): 18-24.

[9] BEIS J S, LOWE D G. Shape indexing using approximate nearest-neighbor search in high-dimensional spaces [C] // Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition. Piscataway, NJ, USA: IEEE, 1997: 1000-1006.

[10] ROTHGANGER F. 3D object recognition using local affine-invariant image descriptors and multi-view spatial constraints [J]. International Journal of Computer Vision, 2006, 66(3): 231-259.

[11] UIUC. 车型数据库 [EB/OL]. (2010-06-01) [2012-03-17]. <http://vangogh.ai.uiuc.edu/silvio/3ddataset2.html>.

[本刊相关文献链接]

吾守尔·斯拉木, 曹巨明. 一种新的散乱点云尖锐特征提取方法. 2012, 46(12): 1-5.

张进华, 李婷, 王孙安, 等. 可变视场下的火灾探测算法. 2012, 46(10): 29-35.

郝元宏, 韩静, 齐春. 一种新的浮选泡沫图像识别方法. 2011, 45(4): 104-108.

温浩, 郭崇慧. 利用粒子群优化的人脸特征提取识别算法. 2010, 44(4): 48-51.

许学斌, 张德运, 张新曼, 等. 基于特征层和二代曲波变换的多模生物特征融合识别方法. 2009, 43(10): 32-36.

吴众欣, 王克, 钱德沛. 利用应用程序特征识别降低网格监控负载的研究. 2009, 43(08): 11-16.

(编辑 武红江)