

基于视觉特征的大范围地形感知

张伟东, 张 伟, 李振鹏, 顾建军

(山东大学控制科学与工程学院, 山东 济南 250061)

摘 要: 提出了一种基于视觉特征的移动机器人大范围地形感知方法. 该方法采用由近及远的学习策略: 首先, 将获取的图像分割并进行尺度归一化, 提取样本中反映颜色的色相特征和反映纹理的局部二值模式 (LBP) 特征作为描述子; 其次, 利用双目视觉将近景的一部分地形样本分为障碍与地面, 将这些样本作为有标签的训练数据构建分类器分类未知样本; 最后, 基于后验概率定义可信度, 对可疑的样本进行重分类, 提高最终分类准确率. 实验结果表明, 该方法可以准确且稳定地实现大范围地形感知.

关键词: 地形感知; 障碍检测; 色相特征; LBP 特征

中图分类号: TP24

文献标识码: A

文章编号: 1002-0446(2015)-03-0369-07

Visual Features for Long-Range Terrain Perception

ZHANG Weidong, ZHANG Wei, LI Zhenpeng, GU Jianjun

(School of Control Science and Engineering, Shandong University, Jinan 250061, China)

Abstract: A visual features based long-range terrain perception method for mobile robots is presented. This approach follows a near-to-far learning procedure. Firstly, the obtained image is segmented and the scale is normalized. Then, hue features for representing the color information and LBP (local binary pattern) features for representing the texture information are extracted. Next, the near field terrain samples are labelled obstacle and ground using stereo vision, and then a classifier is trained with these labelled samples to classify the rest unknown samples. Finally, confidence values are defined based on posterior probability to reclassify the low confident samples for further improving the classification accuracy. Experiment results show that the proposed approach can achieve long-range terrain perception accurately and stably.

Keywords: terrain perception; obstacle detection; hue feature; LBP (local binary pattern) feature

1 引言 (Introduction)

移动机器人地形感知的核心问题在于利用传感器检测周围环境并据此判断出环境中可通行的部分和障碍. 根据传感器的不同主要分为单目视觉检测和立体视觉检测. 利用单目视觉的障碍检测方法主要有图像分割法^[1-2]、光流法^[3]等. 近年来, 基于双目立体视觉的方法更为常见. 其一般流程为左右眼图像立体匹配, 获得视差或深度信息, 再由多种启发式算法得到障碍和可通行区域^[4-6]. 然而, 当前立体相机提供的有效障碍检测范围一般只在 10m ~ 12m^[7] 之内, 这种近视的特性使得机器人的路径选择往往不是最优的. 为了实现远距离大范围地形感知, 还需利用视觉信息, 借助分类算法进行处理.

近年来, 国外团队在 LAGR (learning applied to ground robotics) 平台上的研究取得了一系列成果^[7-9], 这些方法多是采用由近及远的策略, 借助双目相机由立体视觉相关算法得到近景标签, 训练分类器用以分类远景. Procopio 等人^[8] 使用像素邻域颜色 (RGB) 直方图提取窗口特征, 使用过采样、SMOTE 等方法均衡训练样本进行分类; Hadsell 等人^[7] 提出了卷积自编码器 (CAE), 经过离线训练自适应地提取地形特征. 这些方法尚有一些不足之处: 文 [8] 中图像 RGB 值受光照强度影响明显, 在不同光照下结果会发生变化; 文 [7] 的方法包括离线训练 CAE 的阶段, 需要收集大量野外场景作为训练样本并花费较长的训练时间, 另外 CAE 训练好之后只能用于固定大小的窗口, 若要改

基金项目: 国家自然科学基金 (61203253, 61233014); 山东省优秀中青年科学家科研奖励基金 (BS2013DX023); 计算智能与信号处理教育部重点实验室开放课题.

通信作者: 张伟, info@vslab.com 收稿/录用/修回: 2014-11-25/2015-03-14/2015-04-02

变窗口大小, 需重新训练, 其灵活性不足.

在此基础上, 本文采用由近及远的处理策略, 即依靠近景样本分类远景, 将色相 (hue) 特征和 LBP 特征引入地形感知问题, 获得了准确且稳定的局部特征. 在分类时, 根据地形感知问题的实际情况和分类器的特性, 提出了一种新颖且有效的修正机制: 基于后验概率定义分类结果的可信度, 以可信度为指标选出可疑样本进行重分类, 有效地提升了分类准确率, 提高了最终的地形感知结果.

2 特征提取 (Feature extraction)

2.1 尺度归一化

参照文 [7], 估计图中场景的距离, 如图 1, 将每幅图红框内部分分割为 6 幅子图并按照距离远近缩小尺寸, 得到 $P_i, i = 1, 2, \dots, 6$. 按距离缩小子图是由于远景包含的信息密度大于近景, 将图像按距离缩小之后, 会使得不同子图中同样大小的窗口包含的内容更为相似, 同时也会减少原本大量冗余的训练数据, 提高训练速度. 分割时没有包括极近区域 (红框以下部分) 以及超远距离场景 (红框以上部分). 极近区域一般为可通行区域, 因此不再需地形感知; 而由于本文所用数据为野外环境中获得, 图像的顶部区域往往都是天空, 或可以认为是超远距离场景, 对机器人导航并无太大意义, 因此也可以排除在外.




图 1 尺度归一化结果

Fig.1 Scale normalization results

后续的特征提取使用滑动窗遍历 P_1 到 P_6 , 窗

口大小为 20×20 像素, 滑动间隔 2 个像素.

2.2 颜色特征

自然图像中, RGB 三个分量有很强的相关性, 均随光照强度而变, 用于描述颜色特征存在冗余且不具光照不变性. 为了减弱光照强度对颜色特征的影响, 本文选择色相来描述颜色信息. 色相为 HSV 颜色空间的 H 分量, 与光照强度无关, 单纯地反映颜色本身, 如在 hue 环中, 红色为 0° (360°), 绿色为 120° , 蓝色为 240° . 色相的计算公式如下:

$$\text{hue} = \arctan \frac{\sqrt{3}(G-B)}{(R-B) + (R-G)} \quad (1)$$

本文使用色相直方图来描述窗口的颜色特征, 这是因为直方图统计窗口中所有像素色相值的分布, 可以直观而有效地描述窗口的局部颜色特征. 本文选择直方图组数为 30, 即组距为 12° .

根据文 [10] 的结论, 色相在亮度极低时在灰轴 ($R = G = B$) 附近不稳定, 即在上述情形下, 很微小的噪声也会造成色相的较大变动. 为提高特征的稳定性, 需要对直方图进行改进. 考虑到实际情况, 真实的野外地形感知任务中很少会出现亮度极低的情况, 因此只处理后一种情况. 本文采用文 [11] 的方法, 在构建直方图时对每一个采样像素用其饱和度 (saturation) 加权. 在 HSV 空间中, 饱和度 (S) 指的是色彩的纯度. 采样像素饱和度越高, 表示色彩越纯, 则该样本在直方图中权值越大; 随饱和度降低, 像素逐渐变灰, 样本在直方图中权值变小.

2.3 纹理特征

色相特征关注的是局部区域不同颜色所占比例, 而没有包含局部的纹理信息, 为综合反映局部的视觉特征, 本文选择 LBP^[12] 来描述窗口的纹理信息. LBP 是一种图像局部纹理特征, 计算简单且对光照强度不敏感. 原始的 LBP 定义在 3×3 窗口内, 将周围 8 个像素的强度分别与中心像素相比较, 若大于中心像素, 则该位置标记为 1, 否则为 0. 这样得到一个 8 位的二进制数 (转化为 10 进制有 256 种类型), 即为窗口中心像素的 LBP 值. 对于样本窗口, 统计所有 LBP 值出现的频率, 可以得到一个 256 维的向量, 用于描述该窗口的纹理信息. 显然, 原始的 LBP 直方图维数过高, 使得直方图过于稀疏.

为解决这一问题, 本文利用了 Ojala 等人^[13]提出的一种改进后的均匀 LBP 模式 (uniform LBP). 均匀 LBP 需满足对应的二进制序列 (首尾相连) 从 0 到 1 或是从 1 到 0 的跳变总共不超过 2 次. 比如:

00000111 有两次跳变, 属于均匀模式; 10011000 有 4 次跳变, 所以不是均匀模式. 所有的 8 位二进制数中共有 58 个属于均匀模式. 根据文 [13] 的实验结果, 自然图像中大部分 LBP 都属于均匀 LBP, 可达 90% 以上. 将每一种均匀 LBP 分为一类, 共 58 类, 其他所有非均匀 LBP 为第 59 类, 这样直方图从原来的 256 维变成 59 维, 且不会丢失有用信息.

对每一个 20×20 的样本窗口分别提取颜色特征和纹理特征之后, 将得到的 30 维的色相直方图和 59 维的 LBP 直方图连接为 89 维的特征向量, 等待后续分类.

3 地形分类 (Terrain classification)

3.1 立体视觉获取近景标签

本文使用文 [9] 的方法获取近景标签, 这一方

法假设地面是平的, 将高于地面一定程度的部分视为障碍. 以图 1 中原图为例, 基本流程包括: (1) 双目相机左右视图立体匹配, 获得视差图 (图 2(a)); (2) 在正负 10° 范围内旋转视差图, 以视差图下方地面区域各行方差之和最小作为准则选择最合适的角度旋转, 对视差图进行水平校准 (图 2(b)); (3) 根据视差图计算出 V 视差图 (图 2(c)), 利用 Hough 变换检测直线, 检测到的直线即为地面在 V 视差图中的投影, 由此可以估计出地面的视差图; (4) 原视差图减去估计出的地面的视差图, 加以阈值约束, 可以得到障碍的估计结果; (5) 将地面与障碍的估计结果进行形态学闭运算得到最终估计结果 (图 2(d)), 障碍和地面分别标为红色和绿色, 灰色部分表示未知区域. 为了得到可靠的结果而选择较高的阈值, 使得近景标签往往很稀疏.

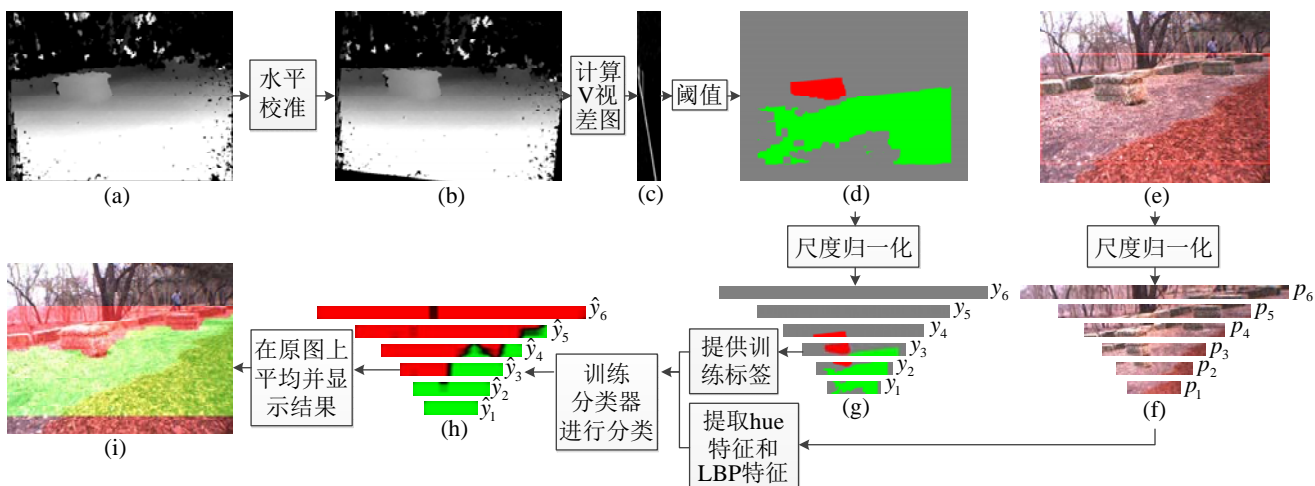


图 2 大范围地形感知主要流程
Fig.2 Main process of long-range terrain perception

利用立体视觉获取近景标签之后, 按照 2.1 节的方法将标签分割并缩放得到 $y_i, i = 1, 2, \dots, 6$ (图 2(g)), 与分割后的彩色图像相对应. 经过尺度归一化, 可以更直观地看出, 由立体视觉得到的标签像素主要集中在较近的 y_1 到 y_3 , 而远距离的 y_4 到 y_6 则只有很少或没有标签像素.

经过尺度归一化, 使用与彩色图相同的 20×20 滑动窗遍历 y_1 到 y_6 , 对每一个窗口, 若其含有有标签的像素, 则统计代表地面与障碍的像素个数, 若代表地面的像素数多于代表障碍的像素数, 则对应窗口的标签记为 +1, 否则标签为 -1. 当以不含标签像素的窗口作为未知样本时, 等待后续分类.

3.2 分类策略

本文选择 RBF (径向基函数) 核 SVM (支持

向量机) [14] 作为分类器, 实现在线监督学习. 对每一帧, 从 P_1 到 P_6 的每个窗口提取特征向量并归一化, 由 3.1 节获取部分近景标签之后, 将有标签的窗口的数据作为训练样本, 训练 SVM, 然后将前帧的未知样本输入分类器进行分类 (图 2(f) ~ (h)). 为了保证结果的一致性, 将已有标签的训练样本也加入分类.


对于移动机器人地形感知任务而言, 近景一般为地面, 障碍较少, 在立体视觉获取的近景标签中, 代表地面的样本数目往往远多于障碍, 可以参照图 2(d). 针对训练样本不平衡的情况, 对每一帧图像, 训练之前首先检测训练样本中正负样本数, 如果发现负样本数不足正样本的 1/3, 则负样本中加入提前准备的负样本集, 该负样本集包含了一些

常见障碍的特征向量, 包括树干、草垛、灌木丛等, 数目约占原训练集样本总数的 15% ~ 20%.

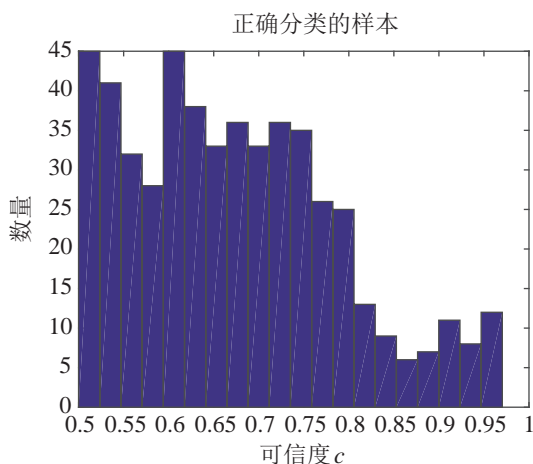
SVM 分类时可以计算后验概率 $P(w_{ij} = \pm 1|x_{ij})$ [15], 定义分类结果的可信度 c :

$$c = \max(P(w_{ij} = +1|x_{ij}), P(w_{ij} = -1|x_{ij})) \quad (2)$$

以上 x_{ij} 和 w_{ij} 分别表示 P_i 上第 j 个窗口对应的 89 维的特征向量和标签. 根据可信度 c 可以画出样本随可信度在 0.5 ~ 1 范围内的直方图. 图 3 是一个典型的可信度直方图, 可以发现, 分类正确的样本绝大多数集中在 c 值很高的区间 (图 3(a)), 而错误分类的样本的 c 值有相当一部分很低 (图 3(b)). 受这一现象的启发, 本文提出一种针对性的分类修正方法: 分类结束后, 计算分类结果的可信度 c , 对所有 $c < 0.9$ 的可疑样本进行重分类.



(a) 正确分类的样本



(b) 错误分类的样本

图 3 典型的样本可信度直方图

Fig.3 A typical confidence histogram

第二次分类与第一次的主要区别在于 SVM 模型中 RBF 核函数选择上. 关于两个样本 x 和 x' , 典型的 RBF 核函数 $k(x, x')$ 如式 (3) 所示:

$$k(x, x') = \exp(-\gamma \|x - x'\|_2^2) \quad (3)$$

式中, 参数 γ 影响 RBF 函数的窗宽, 一般而言, 若 γ 过小, 最终的分界超平面会过于平滑, 导致分类效果在训练集和测试集都不佳; 而若 γ 过大, 会导致分界面的形状过于迎合支持向量样本的分布, 主要作用于支持向量附近, 而对未知样本的效果可能很差.

据此, 第一次分类时选择较小的 γ ($\gamma = 0.001$), 这样可以保证大多数非支持向量有较高的准确率, 相互混杂的部分则容易因为可信度较低而进入第二次分类. 在第二次分类时选择比第一次更大的 γ ($\gamma = 0.03$), 这意味着第二个 SVM 的分界面会比第一个更加灵活与多变, 更适用于分布混杂的样本; 但增大 γ 的副作用是训练更容易过拟合, 这就要求更多的训练数据. 因此, 第二次分类时, 训练样本除了当前帧的数据, 还会加入之前 2 帧的训练数据, 即共 3 帧的数据一起训练. 为此, 每一帧的数据额外储存 2 帧的时间.

3.3 分类结果可视化

本文使用 \hat{y}_i ($i = 1, 2, \dots, 6$) 表示经过分类之后 y_i 对应的预测结果. 由于分类结果分布在 \hat{y}_1 至 \hat{y}_6 的窗口上, 为了在原图上实现分类结果的可视化, 同时减少随机误差, 需要将分类结果进行平均. 首先对 \hat{y}_1 至 \hat{y}_6 的每一幅子图内部的窗口进行平均, 按照式 (4) 进行计算:

$$\hat{y}_i(u, v) = \frac{\sum_{j=1}^n \delta_i(j, (u, v)) w_{ij}}{\sum_{j=1}^n \delta_i(j, (u, v))} \quad (4)$$

式中, $\hat{y}_i(u, v)$ 表示子图 \hat{y}_i ($i = 1, 2, \dots, 6$) 的第 u 行 v 列的像素平均后的标签, w_{ij} ($j = 1, 2, \dots, n$) 表示 \hat{y}_i 中第 j 个窗口的标签, 共 n 个. $\delta_i(j, (u, v))$ 用于表示第 j 个窗口是否包含像素 (u, v) , 若窗口 j 中包含像素 (u, v) , 则 $\delta_i(j, (u, v)) = 1$; 否则 $\delta_i(j, (u, v)) = 0$. 窗口上的分类结果经过子图内部平均之后如图 2(h) 所示.

然后, 将含标签的不同尺寸的子图 \hat{y}_i 根据图 1 按比例恢复为原始大小得到 \hat{y}'_i , 在原图上按照式 (5)、(6) 进行平均:

$$L_{\text{pred}}(u, v) = s \left(\frac{1}{m} \sum_{k=1}^m \hat{y}'_i(u_k, v_k) \right) \quad (5)$$

其中,

$$s(x) = \begin{cases} 1, & x > 0 \\ -1, & x \leq 0 \end{cases} \quad (6)$$

式中, $L_{\text{pred}}(u, v)$ 表示原图第 u 行 v 列的像素第二次平均后的最终预测结果, $\hat{y}_i(u_k, v_k)$ 表示原图中像素 (u, v) 在含有该像素的子图 \hat{y}_k ($k = 1, 2, \dots, m$) 中对应的像素 (u_k, v_k) 的标签. 图 2(i) 为将 L_{pred} 显示在原图上的结果.

4 实验分析 (Experimental analysis)

实验所用的数据集来自 LAGR 测量数据^[6], 有标签的数据共 600 幅, 包括 3 个场景, 每个场景包含两段各 100 帧不同光照下的图像序列以及视差图, 分别为 DS1A、DS1B、DS2A、DS2B、DS3A、DS3B. 数据集由人工标记为地面、障碍和未知 3 类, 考虑到实际情况, 在分类时只分为地面和障碍 2 类. 实验中使用 LIBSVM^[15] 用于分类和计算后验概率, 这是一种常用的 SVM 库, 且包含了计算后验概率的功能.

对各段数据的分类准确率如表 1 所示, 包括单独使用色相直方图、单独使用 LBP 直方图、色相 + LBP 未修正以及修正之后的分类准确率, 此外还包括了根据可信度选出的可疑样本修正前与修正后的准确率. 结果表明, 色相 + LBP 修正后的分类准确率在各段数据中均为最高, 且在不同数据集上表现相对稳定.

单独使用色相直方图与 LBP 直方图的结果在各段数据上互有高低. 对于 DS1A 数据集, 色相特征的结果较差, 是由于 DS1A 的光照条件非常恶劣, 光照太强, 存在饱和、过多的阴影和光斑, 导致色相特征失效; 相比而言, LBP 特征由像素间相对强度得到, 对于强光和阴影不敏感, 在恶劣的光照条件下仍表现正常. LBP 特征在 DS3A 和 DS3B 中表现不佳, 因为在 DS3A 和 DS3B 中, 作为障碍的树叶与地面上的落叶和杂草在纹理上较为相似, 而其颜色有区别, 因此色相特征表现更好.

融合之后的特征在除 DS2B 之外的数据集上均超过了单独的特征, 这说明颜色特征和纹理特征是可以互补的, 融合后的特征可以克服各个特征各自的局限, 提高了准确率, 且更为稳定.

表 1 给出了可疑样本修正前后的数据用于验证分类修正有效性. 可以看出, 由定义的可信度选出的可疑样本在修正之前的平均准确率大大低于所有样本的平均准确率, 这表明以可信度为指标选择可疑样本是有效的. 选出的可信度较低的样本往往很靠近第一次分类的分界超平面, 正确分类的难度较大. 重新分类之后, 可疑样本的准确率有了明显提升, 提高了所有样本的平均准确率, 证明了分类修正机制是合理而有效的.

表 1 分类准确率

Tab.1 Classification accuracy

数据集	分类准确率 /%					
	色相直方图	LBP 直方图	色相 + LBP 未修正	色相 + LBP 修正后	可疑样本未修正	可疑样本修正后
DS1A	69.97	87.27	88.33	89.25	69.52	73.43
DS1B	82.42	85.97	87.67	89.84	69.17	77.14
DS2A	88.74	90.08	90.46	92.16	65.32	74.33
DS2B	84.71	91.23	90.65	91.57	67.94	72.72
DS3A	86.16	82.52	88.34	93.53	69.11	84.59
DS3B	85.51	79.67	87.96	91.40	71.67	79.05

地形感知结果的可视化效果如图 4 所示, 除了本文的方法, 还加入了基于 U-V 视差的方法^[6]、像素邻域颜色直方图过采样 (以下简称为过采样) 方法^[8] 和基于卷积自编码器 (以下简称为 CAE) 的方法^[7] 作为对比, 以数据集中人工标注的结果作为参照. 其中, 基于 U-V 视差的方法单纯使用立体视觉, 而过采样方法和 CAE 方法均利用了立体视觉和彩色图像. 结果中红色和绿色部分分别表示障碍和地面 (在人工标注的结果中蓝色部分表示不确定). 可以看到, 本文的结果较为准确地区分了障

碍与地面, 没有受到地面上外观不一的树叶等杂物干扰, 也没有受阴影等的影响, 相比其他方法, 结果更为平滑.

表 2 给出了本文方法与上述 3 种方法的比较结果, 其中采用均方根误差 (RMSE) 作为评判准则. 结果显示, 本文方法在各个数据集上都得到了最小或接近最小的均方根误差, 且结果较为稳定, 整体表现最好. 基于 U-V 视差的方法不需要彩色图像, 因而不会受到光照变化及场景颜色变化的干扰, 在不同场景中表现稳定; 但其准确率不高, 主要原因

在于距离镜头越远则视差信息越不可靠，单纯基于视差的方法对于远景的识别往往结果较差。过采样方法和 CAE 方法利用了视差和彩色图像视觉信息，分别在 DS1B 和 DS3A 数据集上得到最小的 RMSE，然而这两种方法在不同数据集上的表现非常不稳定，原因在于不同数据集中光照、阴影以及障碍与地面的颜色及纹理均有所变化，而过采样方法和 CAE 方法使用的视觉特征都不够全面：过采样方法

使用像素邻域颜色直方图作为视觉特征，对于地面与障碍颜色相近的场景和光照条件恶劣的场景表现不佳；CAE 方法使用两层堆叠的 CAE 自发提取视觉特征，然而 CAE 提取的特征更接近于原始彩色图像降维的结果，不一定最适合区分不同场景。另外，这两种方法均使用逻辑回归作为分类器，对于复杂环境中样本分布混杂且特征维度不高的情况，线性的分类超平面很难获得令人满意的分类结果。




图4 多种方法地形感知结果对比

Fig.4 Comparison of terrain perception results among several methods

需要说明，数据集中包含了 Procopio 按文 [9] 提供的近景标签，类似于 3.1 节的结果，为了更公平地比较结果且更明显地体现不同算法的差别，本文方法、过采样方法以及卷积自编码器方法的实

验结果均采用了数据集提供的相同的近景标签。此外，计算 RMSE 时图像已经过了 3.3 节所述的两次平均，而平均处理有助于消除随机误差，因此本文方法在各数据集上的表现与表 1 的分类结果有所区

别.

表 2 本文方法与其他方法比较

Tab.2 Comparison between the proposed method and the existing methods

数据集	RMSE			
	基于 U-V 视差	过采样	CAE	本文方法
DS1A	0.351	0.266	0.349	0.202
DS1B	0.313	0.254	0.385	0.254
DS2A	0.271	0.302	0.352	0.218
DS2B	0.283	0.462	0.483	0.266
DS3A	0.237	0.204	0.152	0.192
DS3B	0.251	0.272	0.187	0.185

5 结论 (Conclusion)

本文提出了一种基于视觉的由近及远的大范围地形感知方法. 使用色相直方图作为颜色特征, 均匀 LBP 作为纹理特征, 综合考虑了颜色信息和纹理信息, 保证了特征的准确性与稳定性. 在分类阶段, 采用可信度度量来找出可疑样本, 并为此引入修正机制, 实验证明这种方法有效提高了分类准确率. 下一步的研究将采用无标签的数据集, 实现半监督学习, 提高算法的自适应性.

参考文献 (References)

- [1] Bhoite A, Beke N, Nanduri S, et al. Advanced situational awareness and obstacle detection using a monocular camera[C]// Western New York Image Processing Workshop. Piscataway, USA: IEEE, 2010: 30-33.
- [2] Xia Y Q, Zhi J, Huang M, et al. An obstacle segmentation approach in ALV system[C]//2th International Symposium on Intelligent Information Technology Application. Piscataway, USA: IEEE, 2008: 259-262.
- [3] Pantilie C D, Nedeveschi S. Real-time obstacle detection in complex scenarios using dense stereo vision and optical flow[C]// 13th International IEEE Conference on Intelligent Transportation Systems. Piscataway, USA: IEEE, 2010: 439-444.
- [4] Ventroux N, Schmit R, Pasquet F, et al. Stereovision-based 3D obstacle detection for automotive safety driving assistance[C]// 12th International IEEE Conference on Intelligent Transportation Systems. Piscataway, USA: IEEE, 2009: 394-399.
- [5] Cong Y, Peng J J, Sun J, et al. V-disparity based UGV obstacle detection in rough outdoor terrain[J]. Acta Automatica Sinica, 2010, 36(5): 667-673.
- [6] Zhu X Z, Lu H M, Yang X R, et al. Stereo vision based traversable region detection for mobile robots using U-V-disparity[C]//32th Chinese Control Conference. Piscataway, China: IEEE, 2013: 5785-5790.
- [7] Hadsell R, Sermanet P, Ben J, et al. Learning long-range vision for autonomous off-road driving[J]. Journal of Field Robotics, 2009, 26(2): 120-144.
- [8] Procopio M J, Mulligan J, Grudic G. Coping with imbalanced training data for improved terrain prediction in autonomous outdoor robot navigation[C]//IEEE International Conference on Robotics and Automation. Piscataway, USA: IEEE, 2010: 518-525.
- [9] Procopio M J, Mulligan J, Grudic G. Learning terrain segmentation with classifier ensembles for autonomous robot navigation in unstructured environments[J]. Journal of Field Robotics, 2009, 26(2): 145-175.
- [10] Gevers T, Stokman H. Robust histogram construction from color invariants for object recognition[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2004, 26(1): 113-118.
- [11] van de Weijer J, Schmid C. Coloring local feature extraction[C]//9th European Conference on Computer Vision. Berlin, Germany: Springer-Verlag, 2006: 334-348.
- [12] Ojala T, Pietikainen M, Harwood D. Performance evaluation of texture measures with classification based on Kullback discrimination of distributions[C]//12th International Conference on Pattern Recognition. Piscataway, USA: IEEE, 1994: 582-585.
- [13] Ojala T, Pietikainen M, Maenpaa T. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2002, 24(7): 971-987.
- [14] Cortes C, Vapnik V. Support-vector networks[J]. Machine Learning, 1995, 20(3): 273-297.
- [15] Chang C C, Lin C J. LIBSVM: A library for support vector machines[OL]. (2013-04-04) [2014-11-01]. <http://www.csie.ntu.edu.tw/~cjlin/papers/libsvm.pdf>.
- [16] Mousazadeh H. A technical review on navigation systems of agricultural autonomous off-road vehicles[J]. Journal of Terramechanics, 2013, 50(3): 211-232.
- [17] Procopio M J. An experimental analysis of classifier ensembles for learning drifting concepts over time in autonomous outdoor robot navigation[D]. Boulder, USA: University of Colorado at Boulder, 2007.
- [18] 朱效洲, 李宇波, 卢惠民, 等. 基于视觉的移动机器人可通行区域识别研究综述 [J]. 计算机应用研究, 2012, 29(6): 2009-2013.
Zhu X Z, Li Y B, Lu H M, et al. Research on vision-based traversable region recognition for mobile robots[J]. Application Research of Computers, 2012, 29(6): 2009-2013.
- [19] 王明军, 周俊, 屠珺, 等. 基于条件随机场的大范围地形感知框架 [J]. 机器人, 2010, 32(3): 326-333.
Wang M J, Zhou J, Tu J, et al. Long-range terrain perception based on conditional random fields[J]. Robot, 2010, 32(3): 326-333.
- [20] Halatci I, Brooks C A, Iagnemma K. Terrain classification and classifier fusion for planetary exploration rovers[C]//IEEE Aerospace Conference. Piscataway, USA: IEEE, 2007: 1-11.

作者简介:

张伟东 (1990-), 男, 博士生. 研究领域: 机器视觉, 模式识别, 机器人.

张伟 (1981-), 男, 博士, 副研究员. 研究领域: 机器视觉, 机器学习, 人工智能, 机器人.

李振鹏 (1990-), 男, 硕士生. 研究领域: 机器视觉, 模式识别, 机器人.