光电技术及应用

DOI：10.16818/j.issn1001－5868.2023020602

基于车载视频图像的道路消失点检测算法

代少升，唐臻真*

（重庆邮电大学 通信与信息工程学院，重庆 400065）

摘　要： 道路消失点检测是高级驾驶辅助系统中盲区监测的重要组成部分。针对现有消失点检测方法所存在的准确度低、运算量大等问题，提出一种基于车载视频图像的道路消失点检测算法。该算法在Harris角点检测基础上优化得分函数检测出图像特征点，减少在跟踪阶段的运算量；通过金字塔光流法和帧差距离对运动特征点进行跟踪，在结束帧上准确获得各特征点的位置；对特征点去除离值点后，通过优化初始聚类中心的K-Means聚类算法，得到车载视频图像的道路消失点。最后将算法应用于各种车辆行驶场景进行测试，在较短运行时间内，能准确检测出车载视频图像中道路消失点，证明算法鲁棒性好、运算简单易实现。

关键词： 消失点检测；特征点检测；光流跟踪；离值点；K-Means

中图分类号： TP391.41；U463.6　**文章编号：** 1001－5868(2023)03－0429－07

Road Vanishing Point Detection Algorithm Based On In-vehicle Video Images

DAI Shaosheng，TANG Zhenzhen

（School of Communication and Information Engineering，Chongqing University of Posts and Telecommunications，Chongqing 400065，CHN）

Abstract： Road vanishing point detection is an important part of blind zone monitoring in advanced driver assistance systems. In view of the problems of low accuracy and large computation of existing vanishing point detection methods，a road vanishing point detection algorithm based on in-vehicle video images is proposed. The algorithm detected the image feature points based on Harris corner point detection by optimizing the score function to reduce the amount of operations in the tracking stage. It tracked the motion feature points by the pyramid optical flow method and frame difference distance，and accurately obtained the position of each feature point on the end frame. After removing the outlying points from the feature points，the K-Means clustering algorithm that optimized the initial clustering center was used to obtain the road vanishing point of the in-vehicle video image. Finally，the algorithm was applied to various vehicle driving scenes for testing. It can accurately detect the road vanishing points in the in-vehicle video images within a short running time，which proves that the algorithm is robust，simple and easy to implement.

Key words： vanishing point detection；feature point detection；optical flow tracking；off-value point；K-Means

0　引言

现如今，高级驾驶辅助系统（ADAS）已成为提高汽车驾驶安全的重要研究方向，其中道路消失点的检测是道路区域划分与盲区监测的重要组成部分。在车辆行驶过程中，夜晚路灯、周围绿植、密集

收稿日期：2023－02－06.

* **通信作者：**唐臻真　**E-mail：**1582796345@qq.com

车辆、高大建筑等复杂道路环境是影响消失点检测准确度的重要因素。同时，算法运算量也是决定算法实用性的重要指标。为解决道路消失点检测时准确度和运算量两大问题，国内外学者针对不同道路场景，提出了不同方法。

其中对于乡村、街巷等颜色、边界不明显道路场景，Rasmussen[1]使用 Gabor 滤波器提取图像各像素的纹理主方向，结合全局硬投票得到消失点。该方法能准确检测出部分道路消失点，但存在运算量大的问题。为此 Kong 等[2]提出的全局软投票在一定程度上减少了运算量，却容易受到场景中竖直建筑物的干扰，使得检测出的消失点位置上移。傅重添等[3]则采用快速局部投票算法估计消失点的位置，在一定程度上改善了干扰问题提高了准确率。徐建华等[4]使用区域生长算法和对投票点权重加强，增强图像感兴趣区域的纹理提取，从而提高检测的准确性，但算法运算量依然很高。

对于城市道路和高速公路等道路边缘清晰地场景，Hwang 等[5]通过分析单位球域内的线，应用 MST 方法获得的候选消失点组之间的累积聚类大小，以此确定消失点，但该方法效率较低，不利于实时处理的需求。丁利伟等[6]提出一种基于垂线包络和平行线的消失点检测算法，通过提取道路区域直线对并求出交点，再利用 C-means 聚类和统计相结合的方法估计城市道路场景中的消失点，能取得良好检测准确度和低运算量，但在复杂环境下检测效果大打折扣。Khac 等[7]利用车辆行驶中多帧图像获取的角点矢量，结合 RANSAC 算法投票能较为准确地得到道路消失点，但该方法仅能在平坦道路上适用，算法实用性不高。

除此之外，近几年深度学习技术也应用到了消失点的检测中，Li 等[8]将图像划分成为 $N\times N$ 个单元进行编号，使用 AlexNet 作为 VP 的辅助输入，分别对水平和垂直坐标进行分类，在降低复杂度的同时提高准确率。虽然基于深度学习的消失点检测方法在精度与实时性方面相较于传统方法都有大幅度提升，但对硬件性能、计算资源要求和所投成本过高。

目前现有的消失点检测算法，在面对复杂行车环境时，不能同时满足高准确度和运算量小两个要求。本文在现有研究基础上，以 CCD 摄像头采集的车载视频图像做为输入，利用车辆后方道路图像变化规律，采用优化后的 Harris 角点检测方法对初始帧图像进行特征点检测，通过连续多帧光流跟踪[9]，使特征点向道路尽头聚集，并采用改进的 K-Means 聚类算法[10]准确获取道路消失点。本文通过减少特征点数量使跟踪时遍历次数减少，从而减少算法运算量，同时适用于多种复杂场景。

1 特征点检测与跟踪

根据车载设备采集的车辆后方道路视频，可发现，车辆后方景物由近及远，终将汇集于后方道路尽头。因此本节主要对初始帧进行特征点检测，通过连续帧跟踪，得到特征点汇集处。

1.1 特征点检测

Harris 角点检测能检测出车载视频图像中特征点。在图像上方设定一个可在各方向上移动的窗口，移动前后窗口内像素值变化很小，则为平坦区域；沿一方向变化较小，垂直于该方向变化较大，则为边缘特征；若往任意方向移动，像素值都会发生较大变化则该框区域为一个角点，即特征点，如图 1。

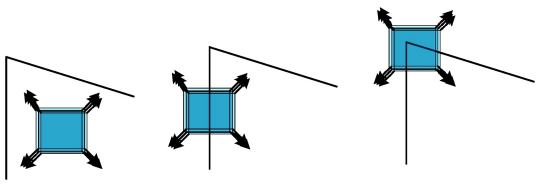


图 1 检测框检测是三种情况图

假设一个的窗口中心位置为(x,y)，其灰度值为$I(x,y)$，若该窗口分别在 x 和 y 方向上移动 u 和 v，新位置表示为$(x+u,y+v)$，其值表示为$I(x+u,y+v)$，则所造成的像素灰度值变化量$E(u,v)$表示为：

$$E(u,v)=\sum_{(x,y)}w(x,y)\times[I(x+u,y+v)-I(x,y)]^2 \tag{1}$$

式中，$w(x,y)$为窗口函数。对一个角点来说，$E(u,v)$的值会很大，为提高函数计算速度引入泰勒一阶展开式：

$$T(x,y)\approx f(u,v)+(x-u)f_x(u,v)+(y-u)f_y(u,v)+\cdots \tag{2}$$

得到：

$$E(u,v)=\sum_{(x,y)}w(x,y)\begin{bmatrix}u & v\end{bmatrix}\begin{bmatrix}I_x^2 & I_xI_y\\ I_xI_y & I_y^2\end{bmatrix}\begin{bmatrix}u\\ v\end{bmatrix} \tag{3}$$

式中，I_x 和 I_y 分别为窗口中心像素的灰度值在 x

和 y 方向上的一阶偏导数[9]，记 $\boldsymbol{M}$ 为：

$$\boldsymbol{M}=\sum_{(x,y)}w(x,y)\begin{bmatrix}I_x^2 & I_xI_y\\ I_xI_y & I_y^2\end{bmatrix} \tag{4}$$

则式(3)可表示为：

$$\boldsymbol{E}(u,v)\approx\begin{bmatrix}u & v\end{bmatrix}\boldsymbol{M}\begin{bmatrix}u\\ v\end{bmatrix} \tag{5}$$

经对角化处理后，可提取出 $\boldsymbol{M}$ 矩阵的特征值 λ_1，λ_2。将特征值带入角点响应函数式(6)得到窗口得分。

$$R=\lambda_1\lambda_2-k(\lambda_1+\lambda_2)^2 \tag{6}$$

k 为经验常数，取值范围为(0.04，0.06)。当 R 值很大时，这表示该处为一个角点。

1.2　特征点跟踪

利用 L-K 光流法[9]进行连续多帧跟踪可得到特征点最终位置，通过相邻帧之间同一空间点在相邻帧图像上形成的像素对应关系，确定初始特征点在相邻帧图像上所处位置。其相邻帧需满足三个条件：

1)亮度恒定：同一像素点随时间变化其亮度不变；

2)时间连续或“小运动”：时间变化不会因其位置剧烈变化；

3)空间一致：同一场景的相邻点投影到图像上也为相邻点，且瞬时速度一致。

对图像上一点 (x,y)，其在时间 t 时刻的灰度值为 $I(x,y,t)$，在时间 $t+\Delta t$ 时刻该点分别在 x 和 y 方向上移动 Δx 和 Δy，灰度值为 $I(x+\Delta x,y+\Delta y,t+\Delta t)$，由亮度恒定可得：

$$I(x,y,t)=I(x+\Delta x,y+\Delta y,t+\Delta t) \tag{7}$$

由时间连续，利用泰勒级数对公式(7)展开，得到公式(8)：

$$\frac{\partial I}{\partial x}\Delta x+\frac{\partial I}{\partial y}\Delta y+\frac{\partial I}{\partial t}\Delta t=0 \tag{8}$$

化简并写成矩阵形式得到：

$$\begin{bmatrix}I_x & I_y\end{bmatrix}\begin{bmatrix}u\\ v\end{bmatrix}=-I_t \tag{9}$$

式中，I_x，I_y，I_t 分别为灰度值 $I(x,y,t)$ 的偏导，u 和 v 分别表式点在 x 和 y 方向上的瞬时速度，即为 $I(x,y,t)$ 的光流。求解出 u 和 v，在公式(9)的基础上构建新的光流方程，即为光流公式。

根据空间一致，取一个大小为 $w\times w$ 的窗口 S，则在该窗口内像素具有相同运动，可得到超定方程：

$$\begin{bmatrix}I_x & I_y\end{bmatrix}_k\begin{bmatrix}u\\ v\end{bmatrix}=-I_{tk},k=1,2,\cdots,w^2 \tag{10}$$

记：$\boldsymbol{A}=\begin{bmatrix}\begin{bmatrix}I_x & I_y\end{bmatrix}_1\\ \vdots\\ \begin{bmatrix}I_x & I_y\end{bmatrix}_k\end{bmatrix}$　$\boldsymbol{b}=\begin{bmatrix}I_{t1}\\ \vdots\\ I_{tk}\end{bmatrix}$

则可将公式(10)写为公式(11)：

$$\boldsymbol{A}\begin{bmatrix}u\\ v\end{bmatrix}=-\boldsymbol{b} \tag{11}$$

利用最小二乘法计求得近似解，如下式所示：

$$\begin{bmatrix}u\\ v\end{bmatrix}^*=-(\boldsymbol{A}^{\mathrm{T}}\boldsymbol{A})^{-1}\boldsymbol{A}^{\mathrm{T}}\boldsymbol{b}=\begin{bmatrix}\sum\limits_{w^2}I_x^2 & \sum\limits_{w^2}I_xI_y\\ \sum\limits_{w^2}I_yI_x & \sum\limits_{w^2}I_y^2\end{bmatrix}^{-1}\cdot\begin{bmatrix}-\sum\limits_{w^2}I_xI_t\\ -\sum\limits_{w^2}I_yI_t\end{bmatrix} \tag{12}$$

当 $(\boldsymbol{A}^{\mathrm{T}}\boldsymbol{A})$ 可逆时，则可求得当前点的光流，在实际的运动过程中，在有灰度骤变的边缘或有线条相交位置的点，存在能使矩阵可逆的特征向量。

1.3　改进的特征点检测与跟踪算法

Harris 角点检测能够检测出车载视频图像所有特征点，但大量特征点的跟踪增大算法运算量，同时算法稳定性与经验值 k 有关，对复杂场景 Harris 无法设置最佳值。且在车辆实际运动中，由于车速较快，光流法三个条件不易满足，相邻两帧之间容易出现位置变化较大的情况，导致所求光流值存在较大误差。本文通过提取具有特征代表性的强角点，减少初始特征点数量，降低算法运算量。同时优化传统 L-K 光流跟踪减少误差。具体步骤如下：

(1)根据大小为 size 的初始帧图像，计算出窗口化简后矩阵 $\boldsymbol{M}$ 的两个特征值 λ_1，λ_2，由于角点稳定性与矩阵 $\boldsymbol{M}$ 较小特征值有关，设定特征值阈值如式(13)，提取满足 $\lambda<\min(\lambda_1,\lambda_2)$ 的角点；

$$\lambda=Q_l\times\max(\lambda_1,\lambda_2) \tag{13}$$

(2)对每一相邻帧采用递归方式建立图像金字塔，从底层至顶层图像分辨率依次减小，从最底层开始，通过与[0.25　0.5　0.25]的低通滤波器卷积得到上一层图像，图像层数为 L；

(3)根据上一帧特征值位置，从顶层开始计算每一层光流值与初始光流值相加后，传递至下一层作为初始光流值，直到达到底层图像为止，得到前帧图像上初始特征点所处位置，如图 2 所示；

(4)计算相邻两帧间特征点位置距离，若距离变

化过大则删除该特征点不再进行跟踪；

(5)若特征点数低于数量阈值 x 时，重新检测强角点，删除与旧特征值重合的点后并为一个集合；

(6)重复步骤(2)到(5)，直至帧数 n 满足阈值。

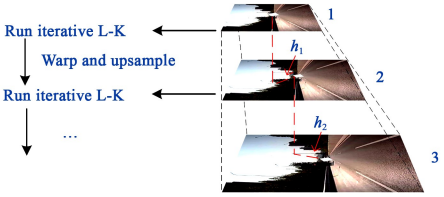


图 2 金字塔特征算法示意图

图 3 左图为 Harris 检测效果图，右图为本文检测效果，优化之后的特征点均为图像强角点，初始特征点集数量较前者减少，跟踪阶段的运算量也相应减少；图 4 为具有线条纹理场景中连续 200 帧跟踪后特征点的分布情况，其算法流程如图 5。



图 3 Harris 和本文方法检测效果对比图



图 4 跟踪后特征点分布图

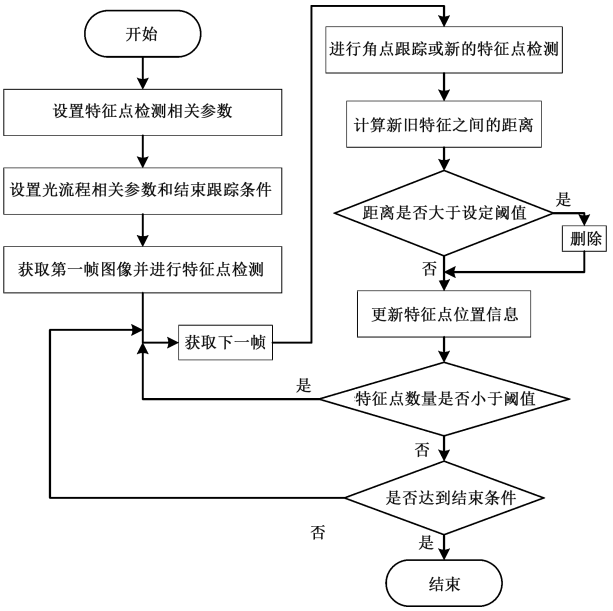


图 5 本文特征点检测与跟踪算法流程图

2 特征点聚类

2.1 *K*-Means 聚类算法

K-Means 方法[10]中数据点围绕聚类的质心收敛，由 James MacQueen 于 1967 年提出，多用于数据分析、信号处理等领域。给定特征点簇集 $\boldsymbol{X}$，包含了 n 个对象 $\boldsymbol{X}=\{\boldsymbol{X}_1,\boldsymbol{X}_2,\boldsymbol{X}_3,\cdots,\boldsymbol{X}_n\}$，其中每个对象都具有 m 个维度的属性，将 $\boldsymbol{X}$ 拆分为 k 个已知数量的子簇集，并随机选择 k 组质心 $\boldsymbol{C}=\{\boldsymbol{C}_1,\boldsymbol{C}_2,\boldsymbol{C}_3,\cdots,\boldsymbol{C}_k\}$，其中 $k\leqslant n$。计算每个对象 $\boldsymbol{X}_i$ 到聚类中心的欧几里得距离，如下式所示：

$$\mathrm{dis}(\boldsymbol{X}_i,\boldsymbol{C}_j)=\sqrt{\sum_{t=1}^{m}(X_{it}-C_{jt})^2} \tag{14}$$

式中，$\boldsymbol{X}_i$ 为 X 中第 i 个对象，$1\leqslant i\leqslant n$；$\boldsymbol{C}_j$ 为第 j 个聚类中心，$1\leqslant j\leqslant k$；X_{it} 为该对象的第 t 个属性，$1\leqslant t\leqslant m$；C_{jt} 为第 j 个聚类中心的第 t 个属性。

通过比较找到每个对象的最小欧氏距离，将其分配到对应的类簇中，可得到 k 个类簇 $\boldsymbol{S}=\{S_1,S_2,S_3,\cdots,S_k\}$ 计算出类簇中心在各维度上的的平均值，计算公式如(15)所示：

$$C_t=\frac{\sum_{X_i\in S_l}X_i}{|S_l|} \tag{15}$$

式中，C_l 为第 l 个聚类中心，$1\leqslant l\leqslant k$；$|S_l|$ 为第 l 个类中对象个数，$1\leqslant l\leqslant k$；X_i 为第 1 个类簇类中第 i 个对象，$1\leqslant i\leqslant|S_i|$。

从计算步骤上可以概括为两步，计算对象到类簇中心的距离和类簇内新的类簇中心。类簇中心的变化是一个更迭的过程，每迭代到一个新的对象都要对类簇中心进行更新。

2.2 *K*-Means 优化算法

原 *K*-Means 聚类算法简单运算量低，但稳定性较差，聚类准确度易受离群点和初始值选取的影响，其聚类效果如图 6 所示，得到的消失点与实际消失点位置误差较大。因此本文从离群点和初始值两方面对 *K*-Means 算法进行优化，来提高聚类准确度。

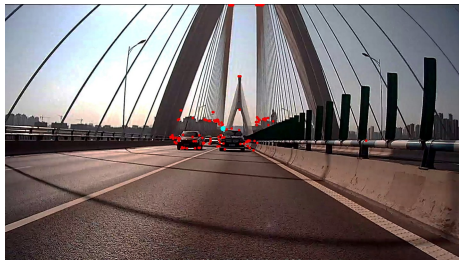


图 6 *K*-Means 算法聚类效果图

2.2.1　针对离群点优化特征点集

为消除因离群点聚类结果产生的偏离，首先对特征点集 $\boldsymbol{X}=\{x_1,x_2,x_3,\cdots,x_N\}$ 中数据排序，让 $x_1\leqslant x_2\leqslant x_3\leqslant\cdots\leqslant x_n$，并按公式(16)和公式(17)计算四分之一值 Q_1 和四分之三值 Q_3：

$$Q_1=x_i \mid i=round((N+1)\times 0.25) \tag{16}$$

$$Q_3=x_i \mid i=round((N+1)\times 0.75) \tag{17}$$

$$lb=Q_1-r\times IQR \tag{18}$$

$$ub=Q_1-r\times IQR \tag{19}$$

计算出两值之差，$IQR=Q_3-Q_1$，通过公式(18)和公式(19)，求出临界值，任何小于 lb 或大于 ub 的值都被视为异常值，其中 i 是数据点索引，N 表示为数据点总数，lb 与 ub 分别为最小估计值与最大估计值，r 是用于调整内在便捷的预定义常量，可根据实际应用选择大小。

2.2.2　改进初始值选取

K-Means 算法中 k 组质心 $\boldsymbol{C}$ 只能由人工指定，在复杂多变的行车环境中适应性较差，从而使聚类结果准确度低。为解决这个问题本文首先从特征点簇集 $\boldsymbol{X}$ 中，随机选取一个对象作为初始聚类中心集合中的第一个对象，记为 $\boldsymbol{C}=\{C_1\}$。

然后计算簇集中每个对象与所选取聚类中心 $C_j(1\leqslant t\leqslant k)$ 之间的最短距离，记为 $D(X)$，$D(X)=\{D_{i1}(X_i,X_1),D_{i2}(X_i,X_2),\cdots,D_{in}(X_i,X_n)\}$。同时通过公式(20)计算样本中每个对象被选为下一个聚类中心的概率。

$$P(X_i)=\frac{D(X_i)^2}{\sum_{X_i\in X}D(X_i)^2} \tag{20}$$

式中，X_i 为簇集中第 i 个对象 $1\leqslant i\leqslant n$，$P(X_i)$ 为该对象被选为下一个聚类中心的概率。最后选择概率最大的对象作为下一个聚类中心 C_{j+1}。重复上述计算步骤，直至 $j+1=k$，结束迭代。

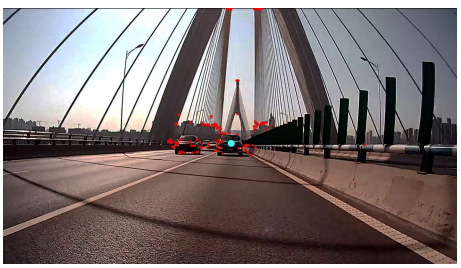


图 7　优化后 K-Means 算法聚类效果图

上述能设置分散且较为合理的聚类初始值。图 7 为优化后 K-Means 聚类算法效果，相较于优化前，算法准确度得到大幅提升。

3　实验结果及分析

3.1　实验环境与参数设定

本文以 CCD 摄像头采集的分辨率为 1 920×1 080 的车载视频图像作为测试输入数据，分析时发现车辆行驶环境主要包括四类，第一类是特征点较少且环境相似的隧道和夜晚路灯环境，第二类是背景空旷被绿植覆盖的环境，第三类是具有线条纹理的环境，第四类是具有较多其他行驶车辆的环境。

实验使用 AMD R7-5800HCPU@3.20 GHz 处理器、16 GB 内存、Windows11(64 位)操作系统，使用 VisualStudio2017＋Opencv3.4.1 集成环境做为软件平台。实验共采集 76 段车载视频，筛选出共 5 788 张图像，其中简单场景 1 213 张，复杂场景 4 575 张。

实验部分的参数来自四个部分，第一部分是预处理图像大小 size 为 640×360 与特征点检测中的 Q_l 为 0.01；第二部分是特征值跟踪时所设图像金字塔层数 L 与连续跟踪帧数 n、特征点数量阈值 x，设为 3，200，100；第三个部分是离群点优化的预定义常量 r 为 1.5，以及聚类算法的初始聚类中心个数 k，k 值通过手肘法选取，设置为 3。

实验部分与传统线条相交方法、文献[4]纹理投票方法进行对比，后面两者均是对单帧图像进行检测。实验步骤如下：

(1)取视频第一帧，修改分辨率为 640×360，并进行初始特征点检测；

(2)继续对视频取帧，并在初始特征点集基础上进行光流跟踪，筛选出符合距离变化的特征点，重复该步骤直至帧数为 200，获得最终特征点集，同时保存最后一帧原始图像；

(3)去除离值点，并设置初始聚类中心进行特征点聚类，在图像上画出聚类结果，并保存坐标，输出程序运行总时间；

(4)分别将所保存原图作为输入，运行线条相交法和纹理投票法代码，得到这两种算法下消失点坐标和程序运行时间；

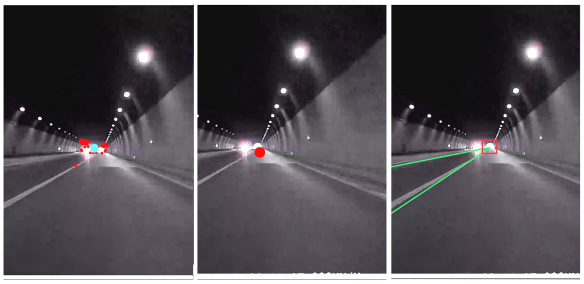
(5)根据实际消失点坐标分析算法准确度，根据程序运行时间分析算法运算量。

3.2　实验结果分析

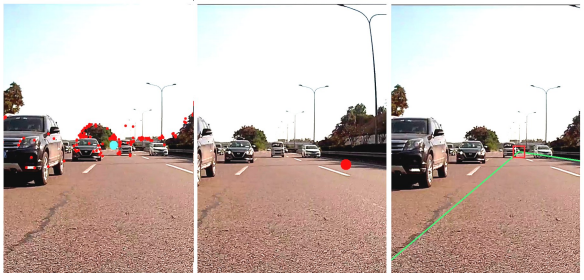
部分实验结果如图 8 所示。



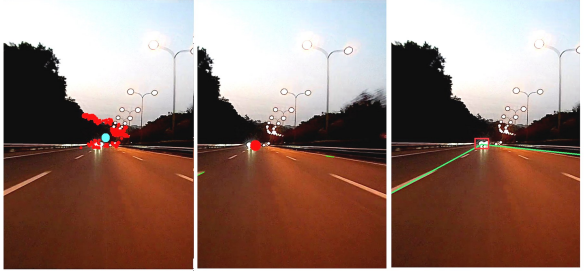
(a) 复杂场景 1(线条纹理建筑)



(b) 复杂场景 2(隧道)



(c) 复杂场景 3(路上车辆较多)



(d) 复杂场景 4(绿植覆盖环境)

图 8 消失点检测效果对比图

检测结果从左至右分别是本文算法、线条相交法、纹理投票法。消失点位置分别由蓝点、红点、红框标出。测试图片涵盖上述的四类场景,对于有明显线条纹理建筑的场景,如吊桥、路灯,线条相交法并不能准确检测出后方道路消失点,纹理投票法的准确度较好,但在后方车辆较多时存在误差,本文方法在各种复杂场景下均能准确检测出车后方道路消失点位置,鲁棒性好。

3.3 实验性能分析

为分析本文算法的准确度和运算量,本节使用归一化欧式距离公式和运行时间来评价[4],如下式所示:

$$Dis=\frac{\sqrt{(x_a-x_t)^2+(y_a-y_t)^2}}{D_i} \tag{21}$$

式中,(x_a,y_a)为图像中道路消失点的实际坐标,(x_i,y_i)为算法检测得到的道路消失点坐标,D_i 为图像的对角线长度。若实际消失点位置与检测出的消失点位置越接近,则表明算法准确度越高[4],检测效果越好;单帧图像所需运行时间越长表示算法运算量越大。详细对比数据如下表 1:

表 1 三种算法与本文算法准确率对比

检测算法	识别率/%	D_{is}	准确度/%	运行时间/s
纹理投票法	95.32	0.037 68	92.74	17.36
线条相交法	91.76	0.045 57	76.57	0.65
本文算法	98.77	0.038 21	95.73	0.04

由表 1 可以看出,相较于两种传统消失点检测方法,本文算法识别率高、准确度高,单帧图像运行时间 t 最少。图 9 所示,实验发现随着检测帧数 n 增加,识别率与准确率增加,运行时间增加,但算法运算量只与初始特征点数量有关。

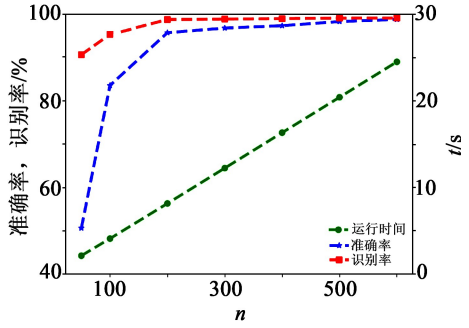


图 9 不同帧数对应的检测率、准确率、运行时间

4 结论

本文从提高后方消失点检测准确度和运算量的角度出发。提出一种基于车载视频图像的道路消失点检测检测算法。该算法以 CCD 摄像头采集的数据作为输入,经预处理后对图像使用优化后的特征点检测与跟踪算法,获得结束帧特征点位置,利用改进的聚类算法得到道路消失点。

测试结果表明:在复杂道路场景下本文提出的道路消失点检测算法具有明显优势,准确率约为 95.73%,平均每帧处理时间约为 40.25 ms,能准确快速检测出道路消失点。

参考文献:

[1] Rasmussen C. Grouping dominant orientations for ill-

structured road following[C]// Proc. of the 2004 IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2004: 1470-1477.

[2] Kong H, Audibert J Y, Ponce J. Vanishing point detection for road detection[C]// Proc. of the 2009 IEEE Conf. on Computer Vision and Pattern Recognition, 2009: 96-103.

[3] 傅重添，杨　健，路飞飞. 基于纹理的复杂环境下道路消失点检测算法[J]. 计算机应用与软件，2014，31(6)：292-294.
Fu Chongtian, Yang Jian, Lu Feifei. Texture-based algorithm for road vanishing point detection in complex environments[J]. Computer Applications and Software, 2014, 31(6): 292-294.

[4] 徐建华，豆毅庚，丁子豪，等. 复杂场景非结构化道路消失点检测算法[J]. 机械工程学报，2022，58(12)：121-129.
Xu Jianhua, Dou Yigeng, Ding Zihao, et al. Unstructured road vanishing point detection algorithm for complex scenes[J]. J. of Mechanical Engineering, 2022, 58(12): 121-129.

[5] Hwang H J, Yoon G J, Yoon S M. Optimized clustering scheme-based robust vanishing point detection[J]. IEEE Trans. on Intelligent Transportation Systems, 2019, 21(1): 199-208.

[6] 丁伟利，李　勇，王文锋，等. 基于垂线包络和平行线对的城市道路图像消失点检测算法[J]. 光学学报，2014，34(10)：186-192.
Ding Weili, Li Yong, Wang Wenfeng, et al. Vanish point detection algorithm for urban road images based on vertical envelope and parallel line pairs[J]. J. of Optics, 2014, 34(10): 186-192.

[7] Khac C N, Choi Y, Park J H, et al. A robust road vanishing point detection adapted to the real-world driving scenes[J]. Sensors, 2021, 21(6): 2133.

[8] Li X X, Zhu L Q, Yu Z J, et al. Adaptive auxiliary input extraction based on vanishing point detection for distant object detection in high-resolution railway scene[C]// 14th IEEE Inter. Conf. on Electronic Measurement & Instruments (ICEMI), 2019: 522-527.

[9] 李成美，白宏阳，郭宏伟，等. 一种改进光流法的运动目标检测及跟踪算法[J]. 仪器仪表学报，2018，39(5)：249-256.
Li Chengmei, Bai Hongyang, Guo Hongwei, et al. A motion target detection and tracking algorithm with improved optical flow method[J]. J. of Instrumentation, 2018, 39(5): 249-256.

[10] Shrifan N H M M, Akbar M F, Isa N A M. An adaptive outlier removal aided *K*-means clustering algorithm[J]. J. King Saud Univ.-Com., 2022, 34(8): 6365-6376.

作者简介：

代少升(1974—)，男，河南省潢川县人，博士，教授，主要从事红外成像系统及 SOPC 嵌入式系统设计与开发。