

改进的 KCF 算法在车辆跟踪中的应用

王 林, 胥中南

(西安理工大学 自动化与信息工程学院, 西安 710000)

摘要: 针对核相关滤波算法 (KCF) 在复杂道路场景下难以应对因车辆尺度变化, 遮挡及旋转而不能继续跟踪的问题, 提出了一种新的跟踪方法来更好地实现复杂道路场景下的车辆跟踪; 该方法借鉴快速分类尺度空间跟踪器 (fDST), 采用一维尺度相关滤波器进行尺度估计; 同时融合 Kalman 滤波器形成预测-跟踪-校准的跟踪机制; 该机制结合遮挡处理能够保证系统在目标被严重遮挡时跟踪的准确性; 在模型更新方面, 在目标被遮挡时, 自适应的调节学习率参数, 及时纠正模型偏移、特征丢失等问题; 实验结果表明, 在复杂道路场景下车辆旋转、遮挡及尺度变化时, 均能有效地跟踪目标车辆, 且具有良好的鲁棒性。

关键词: 复杂背景; 车辆跟踪; 核相关滤波; kalaman 滤波; 尺度空间估计; 遮挡

Application of Improved KCF Algorithm in Vehicle Tracking

Wang Lin, Xu Zhongnan

(College of Automation and Information Engineering, Xi'an University of Technology, Xi'an 710000, China)

Abstract: To cope with the failure in continuously tracking in complex road scenes caused by vehicle scale changes, occlusion and rotation with the kernel correlation filtering algorithm (KCF), a new tracking method is proposed to better realize vehicle tracking under complex road scenes. Making reference to the fast discriminative spatial tracker (fDST), this method makes scale estimations by adopting the one-dimensional scale correlation filter. Meanwhile, the Kalman filter is used to set up a prediction-tracking-calibration tracking mechanism. In the aid of an occlusion processing, it could keep a high accuracy of the system even the target is severely occluded. In terms of model updating, the learning rate parameter is adaptively adjusted, and problems like model offset and feature lose are solved in time when the target is occluded. The experimental results show that the proposed tracking method can effectively track the target vehicle when the vehicle rotates, occludes and scales in complex road scenes, thus has good robustness.

Keywords: complex background; vehicle tracking; kernelized correlation filter; Kalman filter; scale space estimation; occlusion

0 引言

随着我国汽车行业的不断发展, 国民生活水平的不断的提高, 汽车已成为人们日常的代步工具。随之而来的是交通事故的频发, 以及带来的巨大的人身伤害和经济损失, 导致交通事故已经成为全球性安全问题之一。因此, 智能交通系统 (intelligent transportation system, ITS) 作为解决方案被提出并且得到了快速发展。基于视频的车辆跟踪技术已经逐渐成为智能交通系统 ITS^[1] 以及智能交通管理技术的关键技术之一。近年来, 研究人员针对车辆跟踪问题提出了很多优秀的跟踪方法。Wang^[2] 等人通过引入多特征融合方法, 同时利用混合高斯模型体现运动目标的颜色分布, 然后加入空间信息, 将运动目标的多外表所能观察到的特征进行了相应的组合, 最终获得更为精确的目标分析模型。张彤^[3] 等人提出了一种改进的 Mean-Shift 自适应跟踪算法, 通过运动目标的历史信息预测下一帧目标的位置来优化 Mean-Shift 跟踪算法, 该算法具有良好的实时性和鲁棒性。Chang^[4] 等人提出了一种基于车辆部分侧面的实

时车辆跟踪方法。该方法采用 AdaBoost 算法训练不同的弱分类器组成强分类器, 通过 Kalman 滤波预测车辆的每一部分在图像中的位置, 重新定位跟踪窗口。该方法在车辆存在部分遮挡, 光照强弱变化的条件下, 能够有效提高跟踪的效率和准确性。Uchimura^[5] 等人针对遮挡情况下的车辆跟踪, 提出一种基于分块的车辆跟踪算法。该算法将目标车辆以可重叠的方式划分为若干大小一致的子块, 在分块的基础上实现车辆跟踪。建立了马尔可夫随机场描述子块之间的关系, 利用欧氏距离定义块的邻域, 并基于块的直方图构建能量函数, 最后利用模拟退火法对能量函数进行优化, 以对遮挡区域进行分割。单玉刚^[6] 等人针对多目标粘连的问题, 提出了区域运动相似性分割方法和相似度关联矩阵的解决方案。首先采用背景差法进行运动检测, 经过形态学滤波和合并处理提取当前帧中运动目标区域, 然后对检测出含有粘连运动目标区域分别采用基于区域运动一致性分割算法进行车辆粘连分割, 取得较好分割效果, 具有很好的鲁棒性和适用性。Gao^[7] 等人还提出了一种基于 YcbCr 颜色空间的阴影分割算法并采用自动粒子滤波算法对车辆进行跟踪, 跟踪效果具有很强的鲁棒性。

目前常用的车辆跟踪算法包括基于车辆的轮廓、特征、模型、区域的跟踪算法^[8-12]。但是在复杂道路场景下, 相似车辆之间的干扰、严重遮挡、旋转及尺度变换一直是车辆跟踪的难点。因此, 基于视频的车辆跟踪算法仍需要改进。

收稿日期: 2018-12-26; 修回日期: 2019-01-18。

基金项目: 陕西省科技计划重点项目 (2017ZDCXL-GY-05-03)。

作者简介: 王 林 (1962-), 男, 江苏东台人, 硕士生导师, 教授, 主要从事复杂网络、图像处理、大数据、数据挖掘方向的研究。

1 KCF 跟踪器

KCF^[13]跟踪器是以岭回归为核心, 在线训练的一个判别式分类器。该跟踪器的跟踪效果与跟踪速度表现都十分亮眼, 之所以有这么好的效果, 得益于作者使用循环样本矩阵作为分类器的训练样本。然后根据循环矩阵可以离散傅里叶对角化的特性提高了跟踪器的性能。

1.1 样本生成

KCF 跟踪器的训练样本都是在线产生的, 初始化跟踪目标区域为正样本, 然后根据循环矩阵理论分别左乘, 右乘置换矩阵进行图像的循环移位得到负样本集合。记目标样本为向量 $x = [x_1, x_2, \dots, x_{n-1}, x_n]$, x 循环移位可得循环矩阵 \mathbf{X} , 即:

$$\mathbf{X} = C(x) = \begin{bmatrix} x_1 & x_2 & x_3 & \cdots & x_n \\ x_n & x_1 & x_2 & \cdots & x_{n-1} \\ x_{n-1} & x_n & x_1 & \cdots & x_{n-2} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ x_2 & x_3 & x_4 & \cdots & x_1 \end{bmatrix} \quad (1)$$

根据循环矩阵的性质可将其离散傅里叶变换 (DFT) 矩阵对角化为:

$$\mathbf{X} = \mathbf{F} \text{diag}(\hat{x}) \mathbf{F}^H \quad (2)$$

其中: \mathbf{F} 是用来计算 DFT 的常量矩阵; \mathbf{H} 表示矩阵共轭转置; “ \cdot ” 表示一个向量的傅里叶变换, 下文将不在说明。

1.2 分类器的训练

分类器的训练就是在损失函数最小的情况下获的岭回归的最优解, 并且循环矩阵的性质可以简化岭回归的解。线性岭回归目标函数为:

$$\min_w \sum_i (f(x_i) - y_i)^2 + \lambda \|w\|^2 \quad (3)$$

其中: λ 是控制过度拟合的正则化参数, f 为基样本的线性组合, 即:

$$f(x_i) = w^T x_i \quad (4)$$

岭回归的闭式解为:

$$w = (\mathbf{X}^H \mathbf{X} + \lambda \mathbf{I})^{-1} \mathbf{X}^H y \quad (5)$$

其中: \mathbf{I} 为单位矩阵, 也是循环矩阵, 由式 (2) 的性质可得:

$$\hat{w} = \frac{\hat{x} \cdot \hat{y}}{\hat{x} \cdot \hat{x}^* + \lambda} \quad (6)$$

其中: \hat{x}^* 表示 \hat{x} 的复共轭, “ \cdot ” 表示向量对应元素相乘。下文将使用 “ $*$ ” 表示复共轭。

在非线性回归的情况下引入了核函数, 把低维空间的计算映射到高维核空间。假设样本的非线性映射函数为 $\varphi(x)$, 则:

$$f(z) = w^T \varphi(z) \quad (7)$$

根据 Representer 定理得岭回归的最优解:

$$w = \sum_i \alpha_i \varphi(x_i) \quad (8)$$

将 (7) 和 (8) 代入 (3) 式可得核空间的岭回归的解为:

$$\alpha = (\mathbf{K} + \lambda \mathbf{I})^{-1} y \quad (9)$$

其中: $\mathbf{K} = C(\mathbf{K}^{xx}) = \varphi(\mathbf{X}) \varphi(\mathbf{X})^T$ 为所有样本之间的核相关矩阵; α 为系数 α_i 的向量。由 \mathbf{K} 是循环矩阵, 可得 (8) 式频域下的解为:

$$\hat{\alpha} = \frac{\hat{y}}{\hat{k}^{xx} + \lambda} \quad (10)$$

其中: k^{xx} 是核相关矩阵 \mathbf{K} 的第一行。

1.3 快速检测

待检测样本集, 是由上一帧的预测区域和由其循环移位得到的样本集合 $z_j = \mathbf{P}^j z$, \mathbf{P} 为置换矩阵。

对输入图像块 z , KCF 算法中的分类器响应为:

$$f(z_j) = \alpha^T \varphi(\mathbf{X}) \varphi(z_j) \quad (11)$$

由分类器输出最大值的样本区域作为新目标区域, 由 z_j 判断目标移动的位置。

定义 \mathbf{K}^z 是候选图块和训练样本之间的核矩阵, 即:

$$\mathbf{K}^z = \varphi(\mathbf{X}) \varphi(z)^T \quad (12)$$

由于 \mathbf{K}^z 是循环矩阵, 由 (2) 式的性质得到各个候选图块在频域的响应为:

$$\hat{f}(z) = \hat{k}^z \cdot \hat{\alpha} \quad (13)$$

对式 (13) 做离散傅里叶逆运算, 即可获得待检测样本的响应矩阵。采用线性内插法更新模型参数, 即:

$$\hat{x}_t = (1 - \eta) \hat{x}_{t-1} + \eta \hat{x} \quad (14)$$

$$\hat{\alpha}_t = (1 - \eta) \hat{\alpha}_{t-1} + \eta \hat{\alpha} \quad (15)$$

其中: t 是当前帧的序号, η 是学习率, \hat{x} 是预测位置的目标表观模型, $\hat{\alpha}$ 由公式 (10) 得到。

2 多尺度改进

KCF 算法理论上属于一种密度集抽样检测, 利用循环矩阵的性质在傅氏空间中使用离散傅里叶矩阵进行对角化, 将复杂的卷积运算转化为简单的频域相乘, 优化了算法在整个跟踪过程的性能。但是 KCF 算法依赖循环矩阵, 当车辆发生尺度变化时, 初始化的矩阵不能根据实际情况自适应地改变大小。这会导致分类模型的偏移、特征丢失, 最终导致跟踪车辆漂移。所以, 本文提出引入一个在线学习且独立于位置滤波器的快速分类尺度空间跟踪器, 实现快速地尺度估算。

2.1 特征金字塔

在 KCF 算法已经估算出车辆位置的情况下, 在该位置提取训练样本的 S 层主成分分析 (PCA) - HOG 特征金字塔。假设当前目标帧大小为 $P \times R$, 尺度大小为 S , 提取目标大小为 $\alpha^P \times \alpha^R$ 的窗口标记为 J^n 。其中 α 表示一个尺度因子, n 的取值范围如下:

$$n \in \left\{ \left\lfloor -\frac{S-1}{2} \right\rfloor, \dots, \left\lfloor \frac{S-1}{2} \right\rfloor \right\} \quad (16)$$

2.2 尺度降维

文献 [14] 的尺度估计选取 33 个尺度, $S=33$, 训练样本每一个维度的特征 f^l 为一个 $1 \times S$ 的向量, 对 f^l 做一维的离散傅里叶变换得到 \hat{f}^l , 对相关输出 g 做一维的离散傅里叶变换得到 \hat{g} , 最终得到滤波模板 \hat{h}^l , 即:

$$\hat{h}^l = \frac{\hat{g}^* f^l}{\sum_{k=1}^d \hat{f}^{k*} \hat{f}^k + \lambda}, \quad l = 1, \dots, d \quad (17)$$

其中: λ 为正归化参数。

用的新的样本 f_t 更新滤波器 \hat{h}_t^l 的分子 \hat{a}_t^l 和分母 \hat{b}_t , 即:

$$\hat{a}_t^l = (1 - \eta) \hat{a}_{t-1}^l + \eta \hat{g}^* f_t^l, \quad l = 1, \dots, d \quad (18)$$

$$\hat{b}_t = (1 - \eta) \hat{b}_{t-1} + \eta \sum_{k=1}^d \hat{f}_t^{k*} f_t^k \quad (19)$$

其中: $l \in \{1, \dots, d\}$ 表示特征维度。

由于考虑 33 个尺度, 导致大量的离散傅里叶运算, 为了减少计算量, 进行尺度降维, 只考虑 17 个尺度, 即 $S = 17$ ^[15], 改为更新目标模板 $u_t = (1 - \eta) u_{t-1} + \eta f_t$ 。通过傅里叶的线性变换, 可以由 $\hat{a}_t^l = \hat{g}^* F\{u_t^l\}$ 等效地获得滤波器的分子。模板 u_t 用来构造投影矩阵 P_t , 该矩阵定义了投影特征的低维子空间。投影矩阵 P_t 大小为 $\hat{d} \times d$, 其中 \hat{d} 是降维特征表示的维数。利用降维后的样本 $\tilde{f}_t = F\{P_t f_t\}$ 与模板 $\tilde{u}_t = F\{P_t u_t\}$ 进行滤波器地更新, \tilde{f}_t 为降维后样本的离散傅里叶变换, 即:

$$\tilde{a}_t^l = \hat{g}^* \tilde{u}_t^l, \quad l = 1, \dots, \hat{d} \quad (20)$$

$$\tilde{b}_t = (1 - \eta) \tilde{b}_{t-1} + \eta \sum_{k=1}^{\hat{d}} \tilde{f}_t^{k*} \tilde{f}_t^k \quad (21)$$

分别通过 u_t 与 f_t 的 QR 分解获得投影矩阵 P_t^u 与 P_t^f 进行尺度滤波器的更新。使用降维后的待检测样本 $\tilde{z}_t = F\{P_t^u z_t\}$ 应用上述滤波器得到响应图。降维后尺度 $S = 17$, 利用三角插值法将尺度数量从 17 插值到 33, 获得更精确的尺度定位。相比于文献 [14] 的尺度估计方法速度提高了一倍。

3 遮挡处理机制

核相关滤波算法在目标跟踪中, 速度和准确度方面具有明显的优势。但在跟踪过程中并不涉及运动目标的状态信息, 当运动车辆发生严重遮挡时, 就会破坏分类模型, 最终导致跟踪失败。因此, 本文提出融合 Kalman 滤波器的跟踪机制, 当目标车辆发生严重遮挡时, 由 kalman 滤波器预测本帧图像中的目标车辆位置, 再由核相关滤波器检测预测坐标周围的窗口, 利用检测结果校准 kalman 滤波器。最终得到本帧图像中目标车辆的位置。

3.1 kalman 滤波算法

kalman 滤波算法的核心思想: 以最小均方误差为最佳估计准则, 根据系统的状态空间向量模型, 利用前一时刻的估计值和当前时刻的观测值, 从而预测出当前时刻目标可能出现的位置。

kalman 滤波分为两部分: 一个是状态方程、另一个是观测方程分别为:

$$\mathbf{x}_k = \mathbf{A}_k \mathbf{x}_{k-1} \quad (22)$$

$$\mathbf{z}_k = \mathbf{H}_k \mathbf{x}_k + \mathbf{v}_k \quad (23)$$

其中: \mathbf{v}_k 、 \mathbf{H}_k 、 \mathbf{z}_k 表示 k 时刻测量噪声、测量矩阵、测量矢量; \mathbf{x}_{k-1} 表示 $k-1$ 时刻的状态矢量。则状态转移矩阵 \mathbf{A} 、初始误差估计 \mathbf{P}_0 、观测矩阵 \mathbf{H} 分别为:

$$\mathbf{A} = \begin{bmatrix} 1 & 0 & \Delta t & 0 \\ 0 & 1 & 0 & \Delta t \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}, \mathbf{P}_0 = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix},$$

$$\mathbf{H} = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \end{bmatrix} \quad (24)$$

式中, $\Delta t = t_k - t_{k-1}$ 。

系统预测过程:

$$\bar{\mathbf{x}}_k = \mathbf{A}_k \bar{\mathbf{x}}_{k-1} \quad (25)$$

$$\mathbf{P}_k = \mathbf{A}_k \mathbf{P}_{k-1} \mathbf{A}_k^T + \mathbf{Q}_k \quad (26)$$

$$\mathbf{K}_k = \mathbf{P}_k \mathbf{H}_k^T (\mathbf{H}_k \mathbf{P}_k \mathbf{H}_k^T + \mathbf{R}_k)^{-1} \quad (27)$$

式中, \mathbf{P}_k 表示预测误差估计; \mathbf{K}_k 表示增益系数矩阵。

系统状态校准过程:

$$\hat{\mathbf{x}}_k = \hat{\mathbf{x}}_{k-1} + \mathbf{K}_k (\mathbf{z}_k - \mathbf{H}_k \hat{\mathbf{x}}_{k-1}) \quad (28)$$

$$\mathbf{P}_k = (1 - \mathbf{K}_k \mathbf{H}_k) \mathbf{P}_k \quad (29)$$

式中, \mathbf{z}_k 表示 k 时刻由核相关滤波器检测的车辆位置中心点坐标。

3.2 遮挡处理

采用文献 [16] 的遮挡判别算法:

- 1) 获取核相关滤波器最大响应值 \max 和该最大响应值目标车辆的位置坐标 pos ;
- 2) 获取 pos 周围满足大于 $\lambda_1 \cdot \max$ 的所有的的位置 pos_i ;
- 3) 获取所有 pos_i 点到 pos 的欧式距离 $response_i$;
- 4) 判断 $\sum_i response_i$ 是否大于阈值 $\lambda_2 \cdot width \cdot height$, 如果大于阈值判断为受到遮挡干扰, 否则判断为未受到遮挡干扰。

其中: λ_1 为遮挡阈值, λ_2 为面积因子; $height$ 、 $width$ 分别为检测样本的高度和宽度。

如果目标车辆未受到遮挡, 则继续使用核相关跟踪算法进行目标车辆的跟踪。如果目标车辆被局部遮挡, 则核相关滤波算法输出结果将不在可信。则使用上一帧图像中目标车辆的状态信息来初始化卡尔曼滤波器的状态向量, $\mathbf{x}_k = [x_k, y_k, x_k', y_k']^T$, 其中 (x_k, y_k) 为目标车辆位置的中心坐标, (x_k', y_k') 为目标车辆位置中心坐标的变化速度。采用卡尔曼滤波器的预测方程预测目标车辆在本帧图像中的位置。当目标车辆被严重遮挡时, 则不能利用核相关滤波器输出结果校准卡尔曼滤波器预测结果。所以, 设 Δd 表示核相关滤波器的检测坐标与卡尔曼波器的预测坐标的欧式距离。正常情况下, Δd 比较小, 设参数 δ , 当 $\Delta d < \delta$ 时, 正常校准。当 $\Delta d > \delta$ 时, 停止卡尔曼滤波器预测结果校准, 直接根据卡尔曼滤波器预测坐标进行跟踪。

4 自适应模板更新

为了提高跟踪算法在复杂情况下的鲁棒性, 相关滤波器每帧都会更新目标模板, 以及时适应目标表现特征的变化。但是, 目标模板的更新过程只基于当前帧, 且学习率参数不能自适应地变化。当目标车辆发生遮挡时, 模板将

丢失目标车辆的特征，导致跟踪失败。所以，当目标车辆被遮挡时，希望适当降低学习率可以一定程度上减少更新误差。因此，当目标车辆被遮挡时，提出一种自适应更新学习率参数的方法。

遮挡判别算法的输出值 $\sum_i response_i$ 是衡量目标车辆被遮挡的程度，因此该值可以作为衡量更新学习率参数的值。为了更好地衡量 $\sum_i response_i$ 的变化，定义：

$$\beta = \mu \frac{\lambda_2 \cdot width \cdot height}{\sum_i response_i} \quad (30)$$

其中： μ 为调节系数。新的学习率参数为：

$$\eta' = \begin{cases} \eta\beta, & \text{if } \sum_i response_i > \lambda_2 \cdot width \cdot height \\ \eta, & \text{else} \end{cases} \quad (31)$$

当目标车辆被遮挡时，使用新的学习率参数进行模板更新。新的学习率 η' 与遮挡程度成反比，当目标车辆被完全遮挡时，学习率 η' 趋于 0，则不更新模板。相比于传统模板更新方式，当目标车辆被遮挡时，可以自适应地调节学习率参数，提高了模板的自适应更新能力。

5 实验参数及结果分析

实验的硬件平台是 A8-4500 M，主频 1.9 GHz，4 G 内存计算机，软件采用 VS 2013 与 OpenCV 3.1.0 编程环境。实验中传统 KCF 算法的参数保持不变。学习因子 η 为 0.02，高斯核标准差 σ 为 0.5，正则化参数 λ 为 0.000 1。本文参数设置如下：一维尺度相关滤波器正则化参数 λ_1 为 0.01，学习因子 η 为 0.025。遮挡阈值 λ_1 为 0.8，面积因子 λ_2 为 0.3，调节系数 μ 为 0.85。本文选取两种不同情况下的道路车辆监控视频进行实验。视频 1 为目标车辆有尺度变化，视频 2 为目标车辆有遮挡和旋转。

5.1 尺度自适应对比试验

利用视频 1 进行尺度自适应对比试验，试验结果部分截图如图 1 所示。图中上、下两行分别表示改进前跟踪算法和改进后跟踪算法的试验结果。从图中可以清楚地看到视频中的汽车由远及近时，汽车的尺寸逐渐变大，改进后算法的跟踪窗口可以精确地随着目标车辆的尺寸变化而变化。

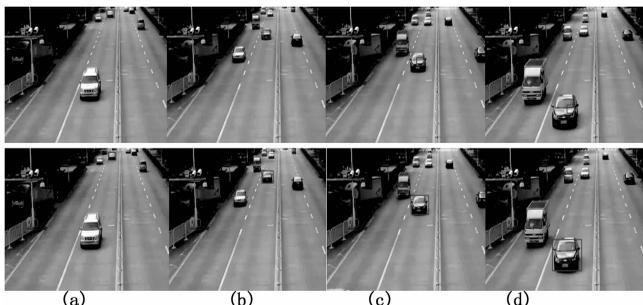


图 1 尺度自适应试验结果对比

5.2 遮挡对比试验

利用视频 2 进行遮挡对比试验，试验结果如图 2 所示。图中上、下两行分别表示改进前跟踪算法和改进后跟踪算

法的实验结果。从图中可以清楚地看到目标车辆在图 2 (b) 中被其他车辆严重遮挡之后，改进前跟踪算法失去了目标车辆，不能继续进行跟踪；改进后跟踪算法借助遮挡处理机制及模板自适应更新在受到严重遮挡，部分遮挡之后仍然可以跟踪目标车辆，跟踪效果良好。此外改进后算法的跟踪速度可以达到 60.5 帧/s，虽然遮挡情况下会影响跟踪的速度但依然大于制式 24 帧/s，可以满足实时性的要求。

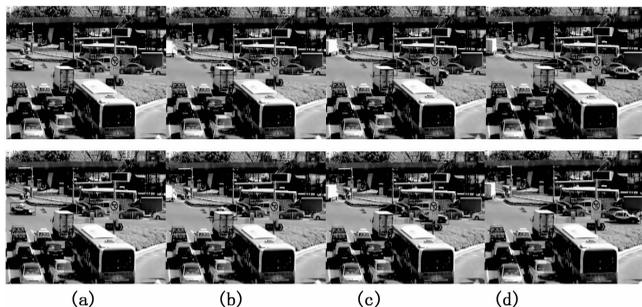


图 2 遮挡试验结果对比

5.3 跟踪性能对比

为了更直观的展示改进后跟踪算法的效果。定义跟踪误差 Δ ，即： $\Delta = \sqrt{(x-x')^2 + (y-y')^2}$ ，其中 (x', y') 为跟踪算法检测的目标车辆中心坐标， (x, y) 为目标车辆实际中心坐标。选用数据集为 Visual Tracker Benchmark 平台中关于车辆的视频序列 Car1 进行实验，实验结果部分截图如图 3 所示。利用跟踪误差 Δ 对跟踪算法进行量化评比，每隔 5 帧获取一帧的跟踪误差，结果如图 4 所示。

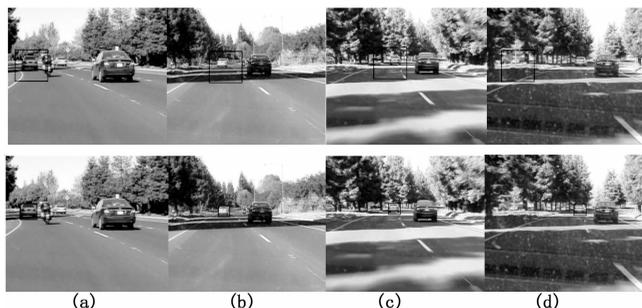


图 3 数据集 Car1 试验结果对比

图 4 (a) 为改进前算法的跟踪误差曲线，图 4 (b) 为改进后算法的跟踪误差曲线。车辆在第 190 帧 (图 3 (a)) 驶入阴影区域之前两种算法的跟踪效果都很好，但是在车辆驶入阴影区域之后改进前算法的跟踪误差明显增大，并且没有进行修正；改进后算法能够一直保持良好的跟踪效果。

6 结束语

鉴于核相关滤波算法的时效性，本文对 KCF 算法进行改进，使之应用到复杂道路场景下的车辆跟踪。(1) 采用快速分类尺度空间跟踪器 (fDSST) 的尺度估计方法，进行尺度降维，相比于文献 [14] 的尺度估计方法速度提高了一倍。(2) 增加遮挡处理机制，通过遮挡判断，融合 kalman 滤波器进行预测跟踪。(3) 在目标被遮挡情况下，自适应调

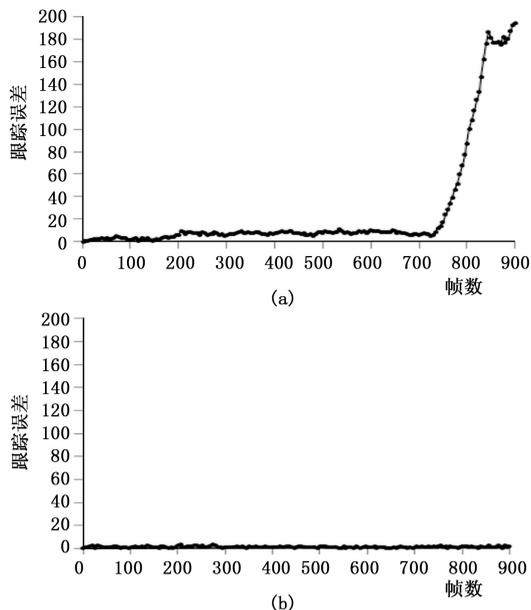


图 4 跟踪误差对比

节学习率参数。实验表明本文方法具有较好的跟踪效果, 并且可以保证跟踪的稳定性与及时性。但跟踪速度相比于传统 KCF 有所降低, 下一步的计划是在不影响跟踪效果的同时, 提高跟踪速度。

参考文献:

[1] Kohshi Abe, Teruo Tobana, Takayuki Sasamor, et al. A Study on a Road-Vehicle Communication System for the Future Intelligent Transport Systems [A]. International Conference on Parallel & Distributed Systems; Workshops [C]. 2000; 343-348.

[2] Hanzi Wang, David Suter, Konrad Schindler, et al. Adaptive Object Tracking Based on an Effective Appearance Filter [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2007, 29 (9): 1661-1667.

[3] 张 彤, 马延柯, 首照宇. 一种改进的 Mean-Shift 实时车辆跟踪算法 [J]. 电视技术, 2015, 39 (17): 126-130.

[4] Chang W C, Cho C W. Real-time side vehicle tracking using parts-based boosting [A]. IEEE International Conference on Systems [C]. 2009; 3370-3375.

(上接第 194 页)

[3] 李金龙, 王 黎, 高晓蓉, 等. 车辆追尾预警系统设计 [J]. 计算机测量与控制, 2011, 19 (5): 1170-1172.

[4] 黄慧玲, 杨 明, 王春香, 等. 基于前方车辆行为识别的碰撞预警系统 [J]. 华中科技大学学报 (自然科学版), 2015 (s1): 117-121.

[5] Song W, Yang Y, Fu M, et al. Real-Time Obstacles Detection and Status Classification for Collision Warning in a Vehicle Active Safety System [J]. IEEE Transactions on Intelligent Transportation Systems, 2018, 19 (3): 758-773.

[6] 刘 军, 高雪婷, 王利明, 等. 基于 OpenCV 的前方车辆检测和碰撞预警算法研究 [J]. 汽车技术, 2017 (6): 11-16.

[7] Dalal N, Triggs B. Histograms of oriented gradients for human

[5] Zhu Z, Lu X B. Video-based Vehicle Tracking Considering Occlusion [J]. Journal of Southeast University (English Edition), 2015, 31 (2): 266-271.

[6] 单玉刚, 汪家宝, 李世兴, 等. 基于运动检测的多车辆跟踪方法研究 [J]. 计算机测量与控制, 2017, 25 (3): 24-28.

[7] Tao G, Liu Z G, Zhang J. Motion Vehicle Recognition and Tracking in the Complex Environment [A]. International Seminar on Future Information Technology & Management Engineering [C]. 2008; 278-282.

[8] Derek R. Magee. Tracking multiple vehicles using foreground, background and motion models [J]. Image & Vision Computing, 2004, 22 (2): 143-155.

[9] Setchell C, Dagless E L. Vision-based road-traffic monitoring sensor [J]. IEEE Image and Signal Processing, 2001, 148 (1): 78-84.

[10] Amir Betser, Patricio Vela, Allen Tannenbaum. Automatic tracking of flying vehicles using geodesic snakes and Kalman filtering [A]. IEEE Conference on Decision & Control [C]. 2004, 2: 1649-1654.

[11] Chen S C, Shyu M L, Zhang C C. An intelligent framework for spatio-temporal vehicle tracking [C]. Intelligent Transportation Systems, 2001; 213-218.

[12] 陈永雷, 胡云安, 赵永涛. 基于动态模板与位置预测的运动目标识别与跟踪 [J]. 海军航空工程学院学报, 2007, 22 (2): 230-232.

[13] JOÃO F. Henriques, Rui Caseiro, Pedro Martins, et al. High-Speed Tracking with Kernelized Correlation Filters [J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2015, 37 (3): 583-596.

[14] Martin Danelljan, Gustav Häger, Fahad Shahbaz Khan, et al. Accurate Scale Estimation for Robust Visual Tracking [A]. British Machine Vision Conference [C]. 2014; 65 (11): 1-65.

[15] Martin Danelljan, Gustav Häger, Fahad Shahbaz Khan, et al. Discriminative Scale Space Tracking [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2016, 39 (8): 1561-1575.

[16] 余礼杨. 基于核化相关滤波器的目标跟踪技术研究及应用系统 [D]. 北京: 北京邮电大学, 2016.

[3] 李金龙, 王 黎, 高晓蓉, 等. 车辆追尾预警系统设计 [J]. 计算机测量与控制, 2011, 19 (5): 1170-1172.

[4] 黄慧玲, 杨 明, 王春香, 等. 基于前方车辆行为识别的碰撞预警系统 [J]. 华中科技大学学报 (自然科学版), 2015 (s1): 117-121.

[5] Song W, Yang Y, Fu M, et al. Real-Time Obstacles Detection and Status Classification for Collision Warning in a Vehicle Active Safety System [J]. IEEE Transactions on Intelligent Transportation Systems, 2018, 19 (3): 758-773.

[6] 刘 军, 高雪婷, 王利明, 等. 基于 OpenCV 的前方车辆检测和碰撞预警算法研究 [J]. 汽车技术, 2017 (6): 11-16.

[7] Dalal N, Triggs B. Histograms of oriented gradients for human

[8] Abhisek Ukil. Support Vector Machine [J]. Computer Science, 2002, 1 (4): 1-28.

[9] Sutton R S, Barto A G. Reinforcement Learning: An Introduction, Bradford Book [J]. IEEE Transactions on Neural Networks, 2005, 16 (1): 285-286.

[10] 王荣本, 李 斌, 储江伟. 公路上基于车载单目机器视觉的前方车距测量方法的研究 [J]. 公路交通科技, 2001 (6): 94-98.

[11] Zhang Z. Camera calibration with one-dimensional objects [J]. IEEE Trans Pattern Anal Mach Intell, 2004, 26 (7): 892-899.