

协同运动状态估计的多目标跟踪算法

袁大龙 纪庆革

(中山大学数据科学与计算机学院 广州 510006) (广东省大数据分析处理重点实验室 广州 510006)

摘要 多目标跟踪在视频分析场景中有着广泛的应用,如人机交互、虚拟现实、自动驾驶、视频监控和机器人导航等。多目标跟踪问题可以表示为在已有的检测数据上进行目标轨迹关联,检测算法的准确性对跟踪性能起着关键性的作用。在基于检测的目标跟踪框架中,提出了一种协同运动状态估计的跟踪算法,该算法主要关注相邻帧之间的数据关联,从目标检测、目标运动状态估计和数据关联这3个方面来直接解决多目标跟踪面临的挑战。首先,对于目标检测,采用 Multi Scale Convolutional Neural Network(MS-CNN)算法作为检测器,这是因为深度学习在检测的效益上优于传统的机器学习方法;其次,为了更好地预测目标的运动状态和处理目标间的遮挡,针对不同状态的目标采取不同的运动估计方法:采用核相关滤波来评估处于跟踪状态的目标的运动状态,当目标处于遮挡状态时,采用卡尔曼滤波做运动估计;最后,采用 Kuhn-Munkres 算法对检测目标和跟踪轨迹做数据关联。通过大量的实验证实了算法的有效性,且实验结果表明算法的准确性很高。

关键词 多目标跟踪,卡尔曼滤波,核相关滤波,数据关联,目标检测

中图分类号 TP391 文献标识码 A

Multiple Object Tracking Algorithm via Collaborative Motion Status Estimation

YUAN Da-long JI Qing-ge

(School of Data and Computer Science, Sun Yat-sen University, Guangzhou 510006, China)

(Guangdong Key Laboratory of Big Data Analysis and Processing, Guangzhou 510006, China)

Abstract Multiple object tracking (MOT) is widely applied in video analysis scenarios, such as human interaction, virtual reality, autonomous driving, visual surveillance and robot navigation etc. MOT can be formulated as a sort of tracklets association in existing detection results, in which the accuracy of detection algorithm is entitled an essential role in tracking performance. We proposed a multiple object tracking algorithm via collaborative motion status estimation. The algorithm is based on the tracking-by-detection framework. The algorithm predominantly focuses on data association of adjacent video frames, tackling challenges of MOT from three aspects: object detection, object motion status estimation and data association. Firstly, as for object detection, multi scale convolutional neural network (MS-CNN) is adopted as the detector, since the advantage of deep learning in detection outweighs that of classical machine learning method. Secondly, to better predict object motion status and handle occlusion among targets, different motion estimation methods are utilized according to different motion statuses. In tracking status, kernelized correlation filter is employed, while in occlusion status, the use of kalman filter is prioritized. Lastly, Kuhn-Munkres algorithm is adopted to work out data association between detections and tracklets. A substantial amount of experiments were carried out to estimate the efficiency. The results are quite positive, demonstrating high accuracy.

Keywords Multiple object tracking, Kalman filter, Kernelized correlation filter, Data association, Object detection

1 引言

多目标跟踪一直是计算机视觉领域中备受关注又富有挑战性的研究方向,在视频分析场景中有着广泛的应用,如人机交互、虚拟现实、自动驾驶、视觉监控和机器人导航等。多目标跟踪问题可以表示为在已有的检测结果上进行轨迹关联,

是一个复杂的问题。该领域还存在诸多挑战,如目标间的遮挡、光照变化、目标间相似的外观等。多目标跟踪的分类方法较多,文献[1]提出了几种不同的分类方法,根据获取目标初始化信息的方式可以分为:基于检测的跟踪(Detection Based Tracking, DBT)和无类别的跟踪(Detection Free Tracking, DFT)。DBT通过特定的检测器来定位每帧中的目标,并在

本文受广东省自然科学基金(2016A030313288),广东省省部产学研合作专项(2013B090500013)资助。

袁大龙(1991—),男,硕士生,主要研究方向为计算机视觉;纪庆革(1966—),男,博士,副教授,CCF高级会员,主要研究方向为计算机图形学、计算机视觉、多媒体和虚拟现实, E-mail: issjqg@mail.sysu.edu.cn(通信作者)。

不同视频帧之间维持多个目标的身份标识号,而 DFT 则需在第一帧手动初始化固定数目的无类别目标,然后在后序视频帧中跟踪上述初始化目标。根据处理数据的方式,多目标跟踪可以分为:在线跟踪(Online Tracking, OT)和离线跟踪(Offline Tracking, FT)。在线跟踪需要逐帧地处理视频序列,可以使用过去和当前视频帧中的数据;而离线跟踪可以批量地处理数据,提前获取所有视频序列中的检测数据,并综合这些检测数据形成最终的轨迹。

近年来,随着目标检测技术的发展,基于检测的跟踪算法框架被广泛关注和使用,这类算法的主要挑战是如何有效地关联视频序列中有噪声的检测数据。数据关联的任务是设计一个相似函数,当目标相对独立且判别力强时,数据关联是非常容易的,但当出现漏检、错检、遮挡或相似的外观表示等情况时,数据关联将是一个棘手的问题。在线跟踪算法可以利用目标的运动和外观表示来缓解数据关联中的模糊性问题,而离线跟踪则可以利用未来视频帧中的数据来解决数据关联的模糊性和检测失败的问题,但这类算法不满足因果关系,因此不适用于机器人导航和自动驾驶等应用。

多假设滤波(MHF)^[2]或联合概率数据关联(JPDA)算法^[3]采用延迟决策来解决数据关联中的模糊性问题,但这类算法的复杂度会随着目标数量的增加呈指数式增长。文献[4]对经典的 JPDA 算法进行了优化,将数据关联问题转化为了整数线性规划问题,使得 JPDA 算法的计算量变得可控,从而可以应用在复杂的场景中。文献[5]通过正则化最小二乘法为每个目标建立外观模型来优化经典的 MHF 算法,使得 MHF 算法达到更高的准确性。许多在线跟踪算法^[6-8]旨在通过在线学习对每个独立的目标构造外观模型,除了外观模型,运动模型^[9]也可以用来辅助数据关联。

许多多目标跟踪算法都会设计一些精巧的方法来处理检测错误和目标出现在边缘的情况,相对于这些算法,本文主要关注帧与帧之间数据关联的有效性和可靠性,从目标检测、目标运动状态估计和数据关联这 3 个方面来解决多目标跟踪中的问题。本文的主要贡献如下:1)采用 MS-CNN 算法^[10]作为检测器来提高检测算法的准确性,从而进一步改善多目标跟踪算法的性能;2)提出了基于核相关滤波^[11]和卡尔曼滤波^[12]的协同估计方法,从而解决了目标间的相互遮挡问题。

本文第 2 节主要介绍所提算法的模块和整体框架;第 3 节对所提算法与其他跟踪算法进行了对比评测,并对实验的结果进行了分析;最后总结全文。

2 算法

2.1 目标检测

对于基于检测的多目标跟踪算法,其检测算法的准确性对跟踪效果有着举足轻重的作用。近年来,得益于深度学习的发展,目标检测技术取得了巨大的突破。本文采用 MS-CNN 算法^[10]作为检测器,该算法主要解决了目标检测中的多尺度问题。MS-CNN 算法由两个子网络组成:候选目标网络和目标检测网络,它们都是端到端的。为了解决目标检测

中的多尺度问题,该算法对不同的层设计不同尺度的目标检测器,对于低层网络,它有更小的感受野,适用于小目标的检测;反之,对于高层网络,适用于大目标的检测。这些不同层次的检测器可以组合成一个强大的多尺度检测器。该检测算法在 KITTI 数据集上的测试对比结果如表 1 所列。MS-CNN 算法可以检测多个目标元类,但本文由于只关注行人的检测,因此只提取行人的检测数据。本文采用该检测算法对 MOT Benchmark^[17]上的训练集和测试集中的图像序列提取行人的检测数据,然后按照标准的格式写入文件中。

表 1 检测算法的对比结果

Method	Time/s	Pedestrians		
		Easy	Mod	Hard
Faster-RCNN ^[13]	2	78.86	65.90	61.18
SDP+RPN ^[14]	0.4	80.09	70.16	64.82
MS-CNN ^[10]	0.4	83.92	73.70	68.31

2.2 目标运动估计

2.2.1 卡尔曼滤波

假设噪声符合高斯分布,卡尔曼滤波利用线性动态系统解决线性最优估计问题。首先, x_k 为离散时域系统在 k 时刻的状态向量, $k+1$ 时刻的状态为:

$$x_{k+1} = F_{k+1,k}x_k + w_k \quad (1)$$

其中, $F_{k+1,k}$ 是从 x_k 到 x_{k+1} 的转换矩阵, w_k 是均值为 0 的系统高斯白噪声,对应的协方差为:

$$E[w_n w_k^T] = \begin{cases} Q_k, & n=k \\ 0, & n \neq k \end{cases} \quad (2)$$

其中, T 表示矩阵转置。 k 时刻的测量值 y_k 是由离散系统的状态变量 x_k 映射出来的,其计算公式为:

$$y_k = H_k x_k + v_k \quad (3)$$

其中, H_k 为测量矩阵, v_k 为均值为 0 的测量高斯白噪声,对应的协方差为:

$$E[v_n v_k^T] = \begin{cases} R_k, & n=k \\ 0, & n \neq k \end{cases} \quad (4)$$

测量噪声与系统噪声之间是相互独立的。线性动态系统的定义如式(1)和式(3)所示。为了解决 x_k 未知状态的问题,卡尔曼滤波的目的是利用所有的测量值 y_1, y_2, \dots, y_k 并通过最小均方差来估计系统的状态向量 x_k ,其递归流程如算法 1 所示,其中 \hat{x}_k^- 为先验状态估计, \hat{x}_k^+ 为后验状态估计, P_k^- 为先验估计误差协方差矩阵, P_k^+ 为后验估计误差协方差矩阵, G_k 为卡尔曼增益。卡尔曼滤波通过测量值构建出系统的状态向量,能有效消除跟踪过程中的噪声干扰,进而准确地估计出目标的位置。本文只关注相邻帧之间的位置估计,目标的位置、速度以及加速度在相邻帧之间的变化较小,因此满足卡尔曼滤波的线性均匀动态系统。

算法 1 卡尔曼滤波

1. 初始化 $\hat{x} = E[x_0]$
 $P_0 = E[(x_0 - E[x_0])(x_0 - E[x_0])^T]$
2. 预测 $\hat{x}_k^- = F_{k,k-1} \hat{x}_{k-1}$
 $P_k^- = F_{k,k-1} P_{k-1} F_{k,k-1}^T + Q_k$

$$G_k = P_k^- H_k^T (H_k P_k^- H_k^T + R_k)^{-1}$$

$$3. \text{更新 } \hat{x}_k = \hat{x}_k^- + G_k (y_k - H_k \hat{x}_k^-)$$

$$P_k = (I - G_k H_k) P_k^-$$

递归进行下一步预测

2.2.2 核相关滤波

核相关滤波跟踪算法^[11]的核心思想在于训练样本的构建,通过循环偏移生成大量的样本来训练分类器,并引入核函数来改善分类器的性能,同时利用傅里叶变换降低计算量。算法包括两个模块:分类器训练和快速目标检测。

为了获得更好的分类性能,核相关滤波跟踪算法将最小二乘线性分类器转换为核化非线性分类器。分类器的训练过程如下,分类器的权重向量为:

$$w = \sum_u a_u \varphi(X_u) \tag{5}$$

其中, a_u 为训练样本 X_u 对应的系数, $\varphi(\cdot)$ 表示将特征空间映射到高维特征空间,从而 w 的求解可以转换为 a 的求解, $a = [a_1, a_2, \dots, a_n]^T$ 。根据文献^[15]可知:

$$a = (K + \lambda I)^{-1} y \tag{6}$$

其中, K 是由所有不同训练样本经过核函数变换组成的核矩阵,即 $K_{i,j} = \kappa(X_i, X_j)$, κ 为核函数, $\kappa(x, x') = \varphi^T(x) \varphi(x')$, 如果核函数满足 $\kappa(x, x') = \kappa(Mx, Mx')$ (其中 M 为任意的转换矩阵),那么核矩阵 K 就是循环矩阵。高斯核函数满足上述等式,因此本文的核函数选用高斯核函数:

$$\kappa(x, x') = \exp(-\frac{1}{\sigma^2} \|x - x'\|^2) \tag{7}$$

K 是循环矩阵,式(7)可以进一步简化为:

$$\hat{a} = \frac{\hat{y}}{\hat{k}^{xx} + \lambda} \tag{8}$$

其中, k^{xx} 是核矩阵 K 的第一行的行向量, \hat{a} 表示 a 的离散傅里叶变换。

快速目标检测过程:在新的一帧图像中,以上一帧目标位置为中心提取大小为 $M \times N$ 的图像块作为候选样本 z ,通过循环偏移来构建所有的候选样本集 $\{P^{i-1} z \mid i = 1, 2, \dots, n\}$,这些候选样本和所有训练样本经过核函数变换生成的核矩阵为:

$$K^z = \kappa(P^{i-1} z, P^{i-1} x) = C(k^{xz}) \tag{9}$$

其中, k^{xz} 表示 x 训练样本和 z 候选样本的相关性,由高斯核函数可得出相关性的公式为:

$$k^{xz} = \exp(-\frac{1}{\sigma^2} (\|x\|^2 + \|x'\|^2 - 2F^{-1}(x^* \Theta x')))) \tag{10}$$

所有候选样本的回归值为:

$$f(z) = (K^z)^T a \tag{11}$$

根据循环矩阵的特性,变换到离散傅里叶域的 $f(z)$ 为:

$$\hat{f}(z) = (\hat{k}^{xz})^* \Theta \hat{a} \tag{12}$$

$f(z)$ 响应图的最大值对应的坐标即为当前帧的目标跟踪位置。

2.2.3 协同跟踪

卡尔曼滤波主要利用目标的运动信息,而相关滤波主要

利用目标的外观特征。为了充分发挥它们的优势,本文对不同状态的目标采用不同的运动估计方法。目标总共有 4 种状态:新生状态、跟踪状态、丢失状态、死亡状态。下面将详细分析这 4 种状态。

1) 新生状态:该状态表示目标首次出现在视频序列中。当检测目标数目大于跟踪目标数目时,没有被关联的检测目标的状态就是新生状态,该目标在初始化完成之后就会转换成跟踪状态。

2) 跟踪状态:该状态表示目标处于稳定跟踪中。在这种状态下,采用核相关滤波进行位置估计。当跟踪目标成功地与检测目标关联时,保持跟踪状态;当与检测目标关联失败时,转换为丢失状态。

3) 丢失状态:当前状态表示目标可能被遮挡或者检测失败。在这种状态下,采用卡尔曼滤波进行位置预测。当成功地与检测目标关联时,转换为跟踪状态,否则依然保持丢失状态,且 T_{Lost} 增加 1 次。

4) 死亡状态:当目标丢失超过 T_{Lost} 帧时,转换为死亡状态,并销毁目标。

综上所述,所提算法可以根据目标的状态采用不同的位置估计方法,其转换过程如图 1 所示。

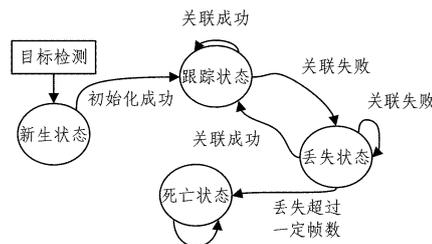


图 1 不同状态之间的相互转换

2.3 关联矩阵的构建

为了将当前帧的检测目标与上一帧的跟踪轨迹进行关联,首先需要构建一个关联代价矩阵。本文采用运动信息^[16]、形状信息^[16]和 IOU (Intersection Over Union) 距离来构建关联代价矩阵,首先采用协同估计方法来得到预测的跟踪目标,检测目标和预测跟踪目标之间的运动关系系数为:

$$aff_{mot}(trk_i, det_j) = e^{-w_1 * ((\frac{X_{trk_i} - X_{det_j}}{W_{det_j}})^2 + (\frac{Y_{trk_i} - Y_{det_j}}{H_{det_j}})^2)} \tag{13}$$

其中, trk_i 表示第 i 个预测跟踪目标, det_j 表示第 j 个检测目标, X_{trk_i} 表示第 i 个预测跟踪目标的 x 坐标, Y_{trk_i} 表示第 i 个预测跟踪目标的 y 坐标, W_{det_j} 表示第 j 个检测目标的宽度, H_{det_j} 表示第 j 个检测目标的高度。检测目标和预测跟踪目标之间的形状关系系数为:

$$aff_{shp}(trk_i, det_j) = e^{-w_2 * ((\frac{|H_{trk_i} - H_{det_j}|}{H_{trk_i} + H_{det_j}})^2 + (\frac{|W_{trk_i} - W_{det_j}|}{W_{trk_i} + W_{det_j}})^2)} \tag{14}$$

检测目标和预测跟踪目标之间的 IOU 距离系数为:

$$aff_{iou}(trk_i, det_j) = \frac{B_{trk_i} \cap B_{det_j}}{B_{trk_i} \cup B_{det_j}} \tag{15}$$

其中, B_{trk_i} 表示第 i 个预测跟踪目标的矩形框。构建的关联矩阵为:

$$M(trk_i, det_j) = 1 - (w_3 * aff_{mot} * aff_{shp} + w_4 * aff_{iou}) \tag{16}$$

最后通过 Kuhn-Munkres 算法得到关联结果的最优解。

本文算法有 3 个模块:检测模块、运动估计模块和数据关联模块。算法的整体框架如图 2 所示。

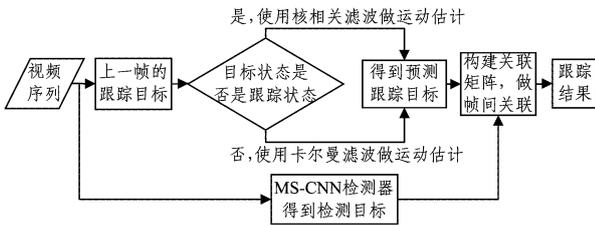


图 2 算法的整体框架

3 实验

3.1 评价指标

本文选取 MOT Benchmark^[17] 中的数据集来对所提跟踪算法进行全面的评估与测试,该数据集中包含 11 个训练集和 11 个测试集,这些数据集包含运动摄像头和静止摄像头拍摄的视频图像序列。所有的实验都采用默认的参数值,实验过程中对应的参数设置为: $T_{lost} = 8$, $w_1 = 1$, $w_2 = 2$, $w_3 = 0.5$, $w_4 = 0.5$ 。

如何评估多目标跟踪算法的性能是一件复杂和困难的事情,本文采用 MOT Benchmark^[17] 中的多个指标来评估算法的性能。第一个性能指标是视频序列中跟踪目标的总个数(GT)。第二个性能指标是误报目标的总数(FP \downarrow)。第三个性能指标为遗漏目标的总数(FN \downarrow)。第四个性能指标是目

标 ID 的改变次数(ID Sw \downarrow)。第五个性能指标是正确跟踪轨迹占 80% 以上的目标比率(MT \uparrow)。第六个性能指标是正确跟踪轨迹占 20% 以下的目标比率(ML \downarrow)。第七个性能指标为轨迹断开的次数(Frag \downarrow)。第八个性能指标为平均每帧中误报的目标数(FAF \downarrow)。第九个性能指标为多目标跟踪准确度(MOTA \uparrow),MOTA 通过 FP, FN 和 ID Sw 这 3 个错误来综合决定,其对应的公式为:

$$MOTA = 1 - \frac{\sum_t FN_t + FP_t + IDS w_t}{\sum_t GT_t} \quad (17)$$

其中, t 表示帧号。第十个性能指标为多目标跟踪精度(MOTP \uparrow),MOTP 表示所有跟踪目标的平均位置矩形框重叠率,其表达式为:

$$MOTP = \left(\sum_{t,i} d_i^t \right) * \left(\sum_t c_t \right)^{-1} \quad (18)$$

其中, c_t 表示第 t 帧中匹配目标的个数, d_i^t 表示第 t 帧中目标 i 的边界框与其对应匹配目标的人工标定的边界框之间的重叠率。指标中的 \uparrow 符号表示得分越高性能越好;反之, \downarrow 符号表示得分越低性能越好。

3.2 实验结果与分析

我们在 MOT Benchmark 提供的 11 个测试集上对算法进行了测试,测试的结果如表 2 所列。同时将所提算法与其他 7 种经典的、当前性能较好的多目标跟踪算法进行比较,这 7 种多目标跟踪算法分别为 TBD^[18], DP_NMS^[19], SMOT^[20], CEM^[21], RMOT^[22], TDAM^[7] 和 MDP^[8],量化性能对比结果如表 3 所列。

表 2 测试集的实验结果

Sequence	MOTA \uparrow	MOTP \uparrow	MT \uparrow /%	ML \downarrow /%	FP \downarrow	FN \downarrow	ID Sw \downarrow	Frag \downarrow	FAF \downarrow	GT
TUD-Crossing	76.3	72.3	61.5	0.0	12	228	21	47	0.1	13
PETS09-S2L2	55.1	72.6	14.3	4.8	405	3638	288	713	0.9	42
ETH-Jelmoli	45.6	78.2	35.6	26.7	565	791	24	79	1.3	45
ETH-Linthescher	67.9	83.1	36.5	16.8	556	2213	95	216	0.5	197
ETH-Crossing	65.8	79.9	26.9	26.9	58	272	13	35	0.3	26
AVG-TownCentre	57.1	71.0	35.8	11.1	580	2092	395	557	1.3	226
ADL-Rundle-1	42.4	75.8	31.3	3.1	1535	3761	66	327	3.1	32
ADL-Rundle-3	44.4	83.2	22.7	25.0	218	5365	68	151	0.3	44
KITTI-16	40.3	71.4	23.5	5.9	344	639	33	93	1.6	17
KITTI-19	29.7	68.9	306.0	16.1	1642	2026	89	307	1.6	62
Venice-1	54.6	77.2	29.4	0.0	511	1521	39	122	1.1	17

表 3 算法的对比实验结果

Tracker	Tracking Mode	MOTA \uparrow	MOTP \uparrow	MT \uparrow /%	ML \downarrow /%	FP \downarrow	FN \downarrow	ID Sw \downarrow	Frag \downarrow	FAF \downarrow
TBD ^[18]	Batch	15.9	70.9	6.4	47.9	14943	34777	1939	1963	2.6
DP_NMS ^[19]	Batch	14.5	70.8	6.0	40.8	13171	34814	4537	3090	2.3
SMOT ^[20]	Batch	18.2	71.2	2.8	54.8	8780	40310	1148	2132	1.5
CEM ^[21]	Batch	19.3	70.7	8.5	48.5	14180	34591	813	1023	2.5
RMOT ^[22]	Online	18.6	69.6	5.3	53.3	12473	36835	684	1282	2.2
TDAM ^[7]	Online	33.0	72.8	13.3	39.1	10064	30617	464	1506	1.7
MDP ^[8]	Online	30.3	71.3	13.0	38.4	9717	32422	680	1500	1.7
KCFKF(Ours)	Online	51.0	76.4	33.0	14.1	6426	22546	1131	2649	1.1

从表 3 中可以得出,本算法在 MOTA, MOTP, MT, ML, FP, FN 和 FAF 这些性能指标上均以较大的优势领先其他算法,但是在 ID Sw 和 Frag 性能指标上分别落后于效果最好的 TDAM 和 CEM,落后的主要原因有:1) 本文仅仅使用了简单的外观特征表示,即当目标间具有相似外观时会产生关联模糊;2) 本文仅关注相邻帧的轨迹关联,无法利用未来帧中的数据来解决关联模糊问题。

图 3 给出了本文算法的部分实验结果,在 TUD-Campus 中,目标 1 从右向左行走时与其他目标发生交叉遮挡或完全遮挡;在 TUD-Crossing 中,目标 3 在行走时出现了形变;在 ETH-Bahnhof 中,摄像头是运动的,目标 1 的尺度大小会随着摄像头的距离而变化,并且在行走时会被其他目标遮挡;在 PETS09-S2L1 中,目标 9 和目标 10 相向而行时出现了合并与分离的情况。实验结果表明,本文算法能对上述情况下的

目标进行准确跟踪并且能处理目标间的遮挡问题,同时具有较强的鲁棒性。



(a) TUD-Campus 图像序列的跟踪结果(依次为第 5, 25, 41 帧)



(b) TUD-Crossing 图像序列的跟踪结果(依次为第 43, 51, 72 帧)



(c) ETH-Bahnhof 图像序列的跟踪结果(依次为第 16, 96, 115 帧)



(d) PETS09-S2L1 图像序列的跟踪结果(依次为第 130, 132, 134 帧)

图 3 本文算法在不同图像序列上的跟踪结果

结束语 本文提出了一种协同运动状态估计的多目标跟踪算法,该算法主要从目标检测、目标运动状态估计和数据关联这 3 个方面来解决多目标跟踪中的问题。首先,本文算法采用 MS-CNN 检测算法来提高目标检测的准确性,从而进一步提高多目标跟踪算法的性能;其次,本文将目标划分为 4 种状态,对不同状态的目标采用不同的运动估计方法,这种协同的运动估计方法能有效处理目标间的遮挡问题,从而使跟踪算法更加鲁棒;最后,利用 Kuhn-Munkres 算法对检测数据和跟踪轨迹进行关联。实验结果表明,所提算法具有很高的准确性和较强的鲁棒性。当目标丢失超过一定帧数时,目标会丢失身份识别号,因此下一步的主要工作是引入行人再识别算法来处理上述问题,让目标产生更完整的轨迹。

参考文献

- [1] LUO W, XING J, ZHANG X, et al. Multiple Object Tracking: A Literature Review[J/OL]. <https://arxiv.org/abs/1409.7618>.
- [2] REID D. An Algorithm for Tracking Multiple Targets[J]. IEEE Transactions on Automatic Control, 1979, 24(6): 843-854.
- [3] FORTMANN T, BAR-SHALOM Y, SCHEFFE M. Sonar Tracking of Multiple Targets Using Joint Probabilistic Data Association [J]. IEEE Journal of Oceanic Engineering, 1983, 8(3): 173-184.
- [4] HAMID REZATOFI G H, MILAN A, ZHANG Z, et al. Joint Probabilistic Data Association Revisited[C]//Proceedings of the IEEE International Conference on Computer Vision, 2015: 3047-3055.
- [5] KIM C, LI F, CIPTADI A, et al. Multiple Hypothesis Tracking Revisited[C]//In Proceedings of the IEEE International Conference on Computer Vision, 2015: 4696-4704.
- [6] BAE S H, YOON K J. Robust Online Multi-Object Tracking based on Tracklet Confidence and Online Discriminative Appearance Learning[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2014: 1218-1225.
- [7] YANG M, JIA Y. Temporal dynamic appearance modeling for online multi-person tracking [J]. Computer Vision and Image Understanding, 2016, 153: 16-28.
- [8] XIANG Y, ALAHI A, Savarese S. Learning to Track: Online Multi-Object Tracking by Decision Making[C]//Proceedings of the IEEE International Conference on Computer Vision, 2015: 4705-4713.
- [9] CHOI W. Near-Online Multi-target Tracking with Aggregated Local Flow Descriptor[C]//Proceedings of the IEEE International Conference on Computer Vision, 2015: 3029-3037.
- [10] CAI Z, FAN Q, FERIS R S, et al. A Unified Multi-scale Deep Convolutional Neural Network for Fast Object Detection[C]//European Conference on Computer Vision, Springer International Publishing, 2016: 354-370.
- [11] HENRIQUES J F, CASEIRO R, MARTINS P, et al. High-

- Speed Tracking with Kernelized Correlation Filters[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 37(3):583-596.
- [12] KALMAN R E. A New Approach to Linear Filtering and Prediction Problems[J]. Journal of Basic Engineering, 1960, 82(1): 35-45.
- [13] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks[C]// Advances in Neural Information Processing Systems. 2015:91-99.
- [14] YANG F, CHOI W, LIN Y. Exploit All the Layers: Fast and Accurate CNN Object Detector with Scale Dependent Pooling and Cascaded Rejection Classifiers[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2016:2129-2137.
- [15] RIFKIN R, YEO G, POGGIO T. Regularized Least-Squares Classification[J]. Nato Science Series Sub Series III Computer and Systems Sciences, 2003, 190:131-154.
- [16] YU F, LI W, LI Q, et al. POI: Multiple Object Tracking with High Performance Detection and Appearance Feature[C]// European Conference on Computer Vision. Springer International Publishing, 2016:36-42.
- [17] LEAL-TAIXÉ L, MILAN A, REID I, et al. MOTChallenge 2015: Towards a Benchmark for Multi-Target Tracking[J/OL]. [https://arxiv.org/abs. 1504. 01942](https://arxiv.org/abs/1504.01942).
- [18] GEIGER A, LAUER M, WOJEK C, et al. 3D Traffic Scene Understanding from Movable Platforms[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2014, 36(5): 1012-1025.
- [19] PIRSAVASH H, RAMANAN D, FLOWKES C C. Globally-Optimal Greedy Algorithms for Tracking a Variable Number of Objects[C]// 2011 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2011:1201-1208.
- [20] DCILE C, CAMPS O I, SZNAIER M. The Way They Move: Tracking Multiple Targets with Similar Appearance[C]// Proceedings of the IEEE International Conference on Computer Vision. 2013:2304-2311.
- [21] MILAN A, ROTH S, SCHINDLER K. Continuous Energy Minimization for Multitarget Tracking[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2014, 36(1):58-72.
- [22] YOON J H, YANG M H, LIM J, et al. Bayesian Multi-object Tracking using Motion Context from Multiple Objects[C]// 2015 IEEE Winter Conference on Applications of Computer Vision (WACV). IEEE, 2015:33-40.

(上接第 122 页)

人到算法中,通过利用混沌现象的特点在局部进行搜索,一方面增加了种群的多样性,另一方面扩大了搜索区域,避免了灰狼个体因种群多样性的不足而陷入局部最优。通过 6 种测试函数的统计结果,CLS-GWO 算法在收敛速度和精度方面得到了明显的提高,并解决了算法在多峰值函数中陷入局部最优的问题。如何在航迹规划中利用 CLS-GWO 的特点进行应用是下一步研究的内容。

参 考 文 献

- [1] SEYEDAIL M, SEYED M M, LEWIS A. Grey wolf optimizer [J]. Advances in Engineering Software, 2014, 69:46-61.
- [2] 罗佳,唐斌. 新型灰狼优化算法在函数优化中的应用[J]. 兰州理工大学学报, 2016, 42(3):96-101.
- [3] 徐达宇,丁帅. 改进 GWO 优化 SVM 的云计算资源负载短期预测研究[J]. 计算机工程与应用, 2017, 53(7):68-93.
- [4] 张新明,涂强,康强,等. 双模狩猎的灰狼优化算法在多阈值图像分割中应用[J]. 山西大学学报(自然科学版), 2016, 39(3):378-385.
- [5] ZHU A J, XU C P. Hybridizing grey wolf optimization with differential evolution for global optimization and test scheduling for 3D stacked SoC[J]. Journal of Systems Engineering and Electronics, 2015, 26(2):317-328.
- [6] 魏政磊,赵辉,韩邦杰,等. 基于自适应 GWO 的多UCAV 协同攻击目标决策[J]. 计算机工程与应用, 2016, 52(18):257-261.
- [7] KENNEDY J, EBERHART R. Particle swarm optimization[C]// IEEE Int Conf on Neural Networks. Piscataway: IEEE, 1995: 1942-1948.
- [8] DORIGO M, STUTZLE T. Ant colony optimization[M]. Cambridge, MA: MIT Press, 2004.
- [9] KARABOGA D. An idea based on bee swarm for numerical optimization[R]. Turkey: Erciyes University, Engineering Faculty, Computer Engineering Department, 2005.
- [10] JIAO B, LIAN Z G, GU X S. A dynamic inertia weight particle swarm optimization algorithm[J]. Chaos, Solitons & Fractals, 2008, 37(3):698-705.
- [11] QIAN S, CHEN D. Discrete Gabor transform[J]. IEEE Transactions on Signal Processing, 1993, 41(7):2429-2438.
- [12] 何鹏,阎兴嶂,何洪波. 一种快速自适应蜂群算法及其应用[J]. 华南理工大学学报(自然科学版), 2013, 39(5):588-595.
- [13] 张永韡,江韬,吴启迪. 动态布谷鸟搜索算法[J]. 控制与决策, 2014, 29(4):617-622.
- [14] 李兵,蒋慰孙. 混沌优化方法及其应用[J]. 控制理论与应用, 1997, 14(4):613-615.
- [15] 柳贺,黄猛,柳桂国,等. 基于混沌搜索和模式搜索的混合优化方法[J]. 华东理工大学学报(自然科学版), 2008, 34(1):126-130.
- [16] 薛毅. 最优化原理与方法[M]. 北京:北京工业大学出版社, 2001.
- [17] 曹璐,贾银平,张安. 基于改进人工蜂群算法的多无人机协同航迹规划[J]. 计算机应用, 2013, 33(12):3596-3599.
- [18] DIGALAKIS J, SMUTNICKI C. On benchmarking functions for genetic algorithm[J]. International Journal of Computer Mathematic, 2001, 77:841-506.