

目标跟踪中目标模型更新问题的半监督学习算法研究

高文 汤洋 朱明

Research on semi-supervising learning algorithm for target model updating in target tracking

Gao Wen Tang Yang Zhu Ming

引用信息 Citation: *Acta Physica Sinica*, 64, 014205 (2015) DOI: 10.7498/aps.64.014205

在线阅读 View online: <http://dx.doi.org/10.7498/aps.64.014205>

当期内容 View table of contents: <http://wulixb.iphy.ac.cn/CN/Y2015/V64/I1>

您可能感兴趣的其他文章

Articles you may be interested in

基于双向稀疏表示的鲁棒目标跟踪算法

[Robust visual tracking algorithm based on bidirectional sparse representation](#)

物理学报.2014, 63(23): 234201 <http://dx.doi.org/10.7498/aps.63.234201>

基于深度玻尔兹曼模型的红外与可见光图像融合

[Infrared and visible image fusion based on deep Boltzmann model](#)

物理学报.2014, 63(18): 184202 <http://dx.doi.org/10.7498/aps.63.184202>

米散射激光雷达剖面数据三次样条垂直水平插值法

[A method of vertical and horizontal plus cubic spline interpolation for Mie scattering lidar profile data](#)

物理学报.2014, 63(15): 154204 <http://dx.doi.org/10.7498/aps.63.154204>

复杂背景下目标检测的级联分类器算法研究

[Study on the cascade classifier in target detection under complex background](#)

物理学报.2014, 63(9): 094204 <http://dx.doi.org/10.7498/aps.63.094204>

基于结构张量的变分多源图像融合

[Variational multi-source image fusion based on the structure tensor](#)

物理学报.2013, 62(21): 214204 <http://dx.doi.org/10.7498/aps.62.214204>

目标跟踪中目标模型更新问题的 半监督学习算法研究*

高文^{1)2)†} 汤洋¹⁾ 朱明¹⁾²⁾

1) (中国科学院长春光学精密机械与物理研究所, 长春 130033)

2) (中国科学院航空光学成像与测量重点实验室, 长春 130033)

(2014年4月17日收到; 2014年5月19日收到修改稿)

本文针对长期稳定的目标跟踪中的目标形变、尺度缩放、旋转等问题, 提出一种步步为营的反馈式学习方法, 该方法通过正、负约束实现对于目标模型和分类器的判别能力和容错能力提高的同时, 使更新带来的误差尽量小, 并证明了其收敛性. 通过实验表明, 对于同一种跟踪算法使用本文提出的目标更新方法进行更新学习的比不更新学习的跟踪效果要稳定得多, 对于目标的尺度变化、形变、旋转、视角变化、模糊等都有较好的适应性, 并通过与现有的较流行的方法进行比较, 本文方法鲁棒性较好, 有很高的研究和应用价值.

关键词: 目标跟踪, 目标模型更新, 半监督学习, 分类器

PACS: 42.30.Va, 42.30.Tz, 07.05.Pj, 02.50.-r

DOI: 10.7498/aps.64.014205

1 引言

视频序列中的目标跟踪在计算机视觉领域有着非常重要的地位和应用.

复杂背景下的目标检测^[1,2]与跟踪一直是图像处理^[3,4]与计算机视觉^[5,6]领域的热门研究方向之一, 其对军事上成像制导、跟踪军事目标等以及民事方面安防监控、智能人机交互等方面均有重要研究价值^[7-9].

目标跟踪^[10]过程中目标会出现不同程度的尺度变化、旋转、形变以及视角变化等, 这些情况下如果始终使用初始化时目标的一个视角建立的模型进行跟踪将导致跟踪失败, 因为对于这个不进行更新的跟踪器来说, 变形了的原始目标已经不再是该跟踪器的目标, 而实际应用中往往要求跟踪器要不断适应目标的各种变化以及背景的亮暗、纹理多少等复杂情况, 那么如果不进行目标模型的更新将无法实时的应用的需要. 然而怎样进行目标更新以

及时何时进行目标更新呢? 最简单的, 用当前帧计算得到的目标代替原始目标重新建模^[11,12], 或者用当前帧计算得到的目标与原始目标进行加权后建模^[13], 这些方法实现简单有一定效果, 半监督学习理论研究利用未标记数据来逐步提升分类器性能, 其非常适合应用于基于分类器的目标跟踪的目标更新问题上, 本文对这方面进行了展开研究.

利用数据结构的学习与自适应目标跟踪有关, 例如逐帧估计目标位置, 目标模型的自适应更新等. 被跟踪的目标可以看作是一个已标记实例, 视频看作是未标记数据. 许多学者利用自学习^[14-17], 这种用跟踪器预测目标, 用靠近当前位置的正实例和远离当前位置的负实例来更新模型. 这种策略能够使跟踪器适应新的外观和背景, 但是只要跟踪器出错这个策略也将失败. 自学习的这个弊端被Rosenberg用互训练^[18]得以解决, 即以跟踪为背景采用互训练来得到可移植的、判别能力强的分类器. 这种跟踪算法有重检测的能力, 在处理一些有挑战性的视频时比自学习效果更好. Kalal等^[19]

* 中国科学院航空光学成像与测量重点实验室开放基金 (批准号: Y2HC1SR121) 资助的课题.

† 通信作者. E-mail: cwenzi@126.com

证实这种互训练方法不适用于目标检测, 因为实例(图像块)是从一个形态中采样得到. 从一个形态中提取的特征可能是相互关联的, 这与互训练的假设前提相违背. 互训练的另一个缺点是他不能利用实例间的数据结构, 因为其认为他们是相互独立的.

本文利用目标在图像中的结构约束进行学习更新, 逐步提升分类器性能以及目标模型的鲁棒性, 符合图像本身的结构特点.

2 半监督学习算法

2.1 半监督学习

半监督学习是利用未标记和已标记的实例来训练分类器, 通过一些学者的实验得其在某些方面有不少的应用效果, 未标记实例可以动态提高分类器的性能.

Zhang 等^[20]对半监督学习进行了进一步分析, 并得出: 如果一个参数化模型 $p(x, y|\theta)$ 能够

分解成 $p(x, y|\theta) = p(y|x)p(x|\theta)$ 的形式, 那么未标记的数据能够帮助分类器更好地估计模型参数 $p(x|\theta)$, 从而提高模型的性能.

事实上, 只有建立未标记的数据分布和预测模型之间的联系, 才能够使未标记数据在学习的过程中发挥效用. 通常地, 通用学习方法需要在某些假设基础上建立未标记数据和预测模型间的联系.

2.2 步步为营反馈式学习方法

大部分普遍的学习算法^[21,22]都假设未标记示例是独立的, 所以, 这些算法不能利用未标记示例间的依赖关系, 而这些关系可能代表着一些非常重要的信息.

在计算机视觉中, 数据是鲜有相互独立的, 因为他们的标签由时-空相关性而联系在一起. 拥有相互关联的标签的数据我们称其为结构(structure).




图1 (网刊彩色) 视频中目标的轨迹代表着一个结构(靠近轨迹的块为正的(蓝色框), 远离轨迹的块为负的, 可以看出当跟踪发生错误时轨迹变化较大)

对于目标检测和目标跟踪, 任务就是在输入图像的各图像块(patch)尽可能地标记为正实例(目标)或者负实例(背景). 一个目标在输入图像中只占有一块. 在视频序列中, 各帧的目标位置被定义为轨迹, 说明见图1. 轨迹代表视频序列中标记的数据的一个结构. 所有接近轨迹的块拥有相同的正标签, 所有远离轨迹的为负标记. 结构数据的其他部分在目标部分的检测或者在一个场景中的目标多类识别. 在这些过程中, 这个图像的标记被预先定义的或者已学习到的空间结构所限制和约束.

已标记的实例非常少, 未标记的结构化实例非常多, 这使得我们得到如下的学习策略: 1) 利用已标记数据训练初始的分类器, 并调整预定义

的约束; 2) 用分类器标记未标记示例, 挑出那些与结构约束相矛盾的已标记数据; 3) 纠正步骤2)中挑出的实例的标签, 加入训练集, 并重新训练分类器. 我们称这种策略为步步为营的反馈式学习(bootstrapping Feedback Learning, BFL).

2.2.1 步步为营的反馈式学习的基本思想

本文提出了一个从结构化未标记示例中进行学习的新构架: 步步为营的反馈式学习(BFL).

这种学习方法的基本思想是首先利用 bootstrapping 思想从已标记数据和大量未标记数据中先采样出一个集合用于初始化分类器, 而后再随机采样出一个集合重新训练分类器, 如此反复以提高初始分类器的性能, 同时采用基于最近邻约束(n-

nearest neighborhood, NN) 的正结构约束 (positive structure constraints, P-constraints) 和负结构约束 (negative structure constraints, N-constraints) 对得到的训练集进行增加和修剪, 以在增加鲁棒性的同时, 降低训练集中的杂质度, 从而形成一个反馈. 如图 2 所示.




图2 BFL 学习

2.2.2 步步为营的反馈式学习的公式化

下面我们将用公式来表征脱线版本的 BFL 算法, 然后推广到在线学习问题. 设:

x 是特征空间 χ 的一个实例;

y 是标签空间 $y = \{-1, 1\}$ 的一个, $y = 1$ 为正, 相反则为负;

X 是实例集;

Y 是 X 对应的标记集;

$f: \chi \rightarrow y$ 是分类器.

BFL 学习的任务是从已标记集 (X_1, Y_1) 学习一个分类器, 然后利用未标记数据逐步提升分类器性能, 如图 2 所示.

分类器 f 是源于以 θ 为参数的一个数族 F 的函数. 类似于监督学习, BFL 学习的分类器相当于从训练集 (X_t, Y_t) 中估计 θ , 训练集由从未标记数据约束后提取的实例反复扩充.

训练过程由插入预先标记的实例到训练集以及估计分类器参数 θ^0 来进行初始化, 然后处理过程反复进行. 在第 k 次迭代, 用 $k-1$ 次训练的分类器给未标记数据分配标签, $y_u^k = f(x_u, \theta^{k-1})$, $x_u \in X_u$.

那些约束条件用于证实被分类器分配的标签是否与数据假设一致. 违背约束的实例的标签被修正, 后加入训练集, 重新训练分类器, 如此迭代直到收敛或者其他停止准则. 整个训练过程, 任何一个实例都可以被选择多次, 甚至可能在训练集中以不同的标记重复表示.

结构化约束可以是接受 (X_u, Y_u^k) 然后输出改

变标签为 (X_c^k, Y_c^k) 的实例子集的任意一个函数. BFL 算法可以使用任意多个这样的约束. 我们将两类约束区分为正结构约束 (P-constraints) 和负结构约束 (N-constraints).

P-约束 (P-constraints) 被用于找出那些已经由分类器标记为负但是约束要求其为一个正标签的实例. 在第 k 次迭代, P-约束增加 $n^+(k)$ 个标签被改为 P 的实例到测试集. 这些约束扩展了正训练集, 所以提高了分类器的泛化能力.

N-约束 (N-constraints) 被用于找出那些已经被分类器分为正但是约束要求其为负的例子. 在第 k 次迭代, N-约束增加 $n^-(k)$ 个标签被改为 N 的实例到测试集. 这些约束扩展了负训练集, 所以提高了分类器的辨别能力.

在许多问题中, 未标记数据 X_u 在训练前是不知道的, 甚至是逐渐得到的. 我们用 $\hat{X}_u^k$ 表示 k 时刻未标记采样集, 则在 k 时刻所有已经看到的未标记采样集为 $X_u^k = \{\hat{X}_u^i\}_{i=1:k}$.

在线学习与脱线学习的一个本质区别在于, 脱线学习的未标记数据是事先知道的, 是确定的, 而对于在线学习, 其未标记数据集是不断增加的, 不完全确定的. 那么, 对于在线的 BFL 学习, 其与脱线的区别在于其未标记的数据在持续增加. 所以上面的对于脱线情况的分析对于在线 BFL 也是适用的.

2.2.3 证明这种正、负结构约束的有效性

设定一个分类器随机为未标记数据分配标记, 而后用约束修正其分配. 约束修正分类器, 但是实际上也引入了不正确重标记的误差. 在 k 次迭代, 分类器误差用错误的正实例 $\alpha(k)$ 和错误的负实例数 $\beta(k)$ 表征.

$n_c^+(k)$: 在 k 次迭代中由 P-约束正确改变为正的实例个数;

$n_f^+(k)$: 在 k 次迭代中被错误改变为正的实例个数.

那么, 由 P-约束改变为正的实例个数为 $n^+(k) = n_c^+(k) + n_f^+(k)$, 同理得由 N 约束改变为负的实例数为 $n^-(k) = n_c^-(k) + n_f^-(k)$, 这里 $n_c^-(k)$ 和 $n_f^-(k)$ 分别代表正确和错误的分配数.

则分类器误差可表示为

$$\alpha(k+1) = \alpha(k) - n_c^-(k) + n_f^+(k), \quad (1)$$

$$\beta(k+1) = \beta(k) - n_c^+(k) + n_f^-(k). \quad (2)$$

方程(1)表明当 $n_c^-(k) > n_f^+(k)$ (即被正确的重新标记为负的实例数高于被错误的重新标记为负的实例数)时, 正误差 $\alpha(k)$ 减小. 同样的, 当 $n_c^+(k) > n_f^-(k)$, $\beta(k)$ 减小.

为分析收敛需要定义一个联系BFL约束和 $n_c^+(k)$, $n_f^+(k)$, $n_c^-(k)$, $n_f^-(k)$ 的模型.

约束的性能由四个量测来表征:

P-精度: $P^+ = n_c^+ / (n_c^+ + n_f^+)$;

P-召回: $R^+ = n_c^+ / \beta$, 即被正确地重新标记为正的实例数量与错误地将其标记为负的实例个数的比例;

N-精度: $P^- = n_c^- / (n_c^- + n_f^-)$;

N-召回: $R^- = n_c^- / \alpha$.

假设整个训练过程中约束被固定不变的量测所表征, 故时间序号可去除. 则 k 次迭代中, 正确和错误的实例个数可表示为

$$n_c^+ = R^+ \beta(k), \quad n_f^+(k) = \frac{(1 - P^+)}{P^+} R^+ \beta(k), \quad (3)$$

$$n_c^- = R^- \alpha(k), \quad n_f^-(k) = \frac{(1 - P^-)}{P^-} R^- \alpha(k). \quad (4)$$

联合上面方程(1), (2), (3), (4)可得

$$\begin{aligned} \alpha(k+1) &= (1 - R^-) \alpha(k) + \frac{(1 - P^+)}{P^+} R^+ \beta(k), \end{aligned} \quad (5)$$

$$\begin{aligned} \beta(k+1) &= \frac{(1 - P^-)}{P^-} R^- \alpha(k) + (1 - R^+) \beta(k). \end{aligned} \quad (6)$$

定义状态向量为 $\mathbf{x}(k) = [\alpha(k) \ \beta(k)]^T$;

转移矩阵为

$$M = \begin{bmatrix} 1 - R^- & \frac{(1 - P^+)}{P^+} R^+ \\ \frac{(1 - P^-)}{P^-} R^- & 1 - R^+ \end{bmatrix}. \quad (7)$$

则可写为 $\mathbf{x}(k+1) = M\mathbf{x}(k)$, 这个递归方程代表了不一个离散动态系统[23].

由动态方程的理论可得, 如果转移矩阵 M 的特征值 λ_1, λ_2 均小于1, 则状态向量 $\mathbf{x}$ 趋于, 约束如果满足上述条件, 则迭代过程误差趋于0.

转移矩阵代表分类器误差在2D空间的一个线性转移, 特征值可以解释为沿特征向量定义的维数的放缩尺度. 特征值小于1, 则误差每次迭代都在减小.

实际中, 不可能证实分类器的所有误差, 所以, 训练不能收敛于无误差状态, 但可能在某个水平上

稳定.

基于以上分析, 我们可进一步得出我们可以联合多个有缺陷的约束以达到无误差. BFL学习对单个约束的性能没有要求, 即使精度非常低的约束只要转移矩阵的特征值 <1 均可用.

3 基于半监督学习算法的目标跟踪

前面我们提出了步步为营的反馈式学习方法, 本小结将利用其具体实现目标跟踪. 为了对于连续图像序列中的快速目标以及目标丢失后重新出现等复杂情况的适应性, 我们采用文献[24]中的Sliding Window搜索策略, 实现对不同尺度目标的鲁棒性. 并采用随机森林分类器[25]进行目标检测跟踪, 对于分类器的训练和更新采用本文提出的方法, 具体流程见图3.




图3 目标跟踪整体流程图

4 实验结果与分析

实验部分是在CPU主频为2.8 GHz内存为2.0 G的PC机上进行的, 共分两部分: 第一部分是对于本文算法自身鲁棒性的评估实验, 实现选取了一组序列, 并选定第一帧中的行人作为实验对象, 对各后续帧逐帧计算, 图4所示为各帧跟踪到的目标

区域, 初始目标为一位行人的前侧面, 整个视频序列中行人一直处于运动状态从而发生了非刚体形变, 并且其旁边有另一位行人相似目标伴随, 行人在整个运动中, 与摄像机所呈的视角也发生了一定角度的超平面旋转, 并伴有一定的尺度缩放, 图中SLTT代表采用本文算法进行目标模型和分类器更新的目标跟踪方法(粉线), TT代表不进行本文算法目标更新的目标跟踪方法(绿线), 从实验结果来看, 对于不进行目标更新的目标跟踪方法, 对于小范围的形变如行人腿的运动(如图4(a), (b), (c), (d), (e)所示), 不更新也有很好的跟踪效果, 但是随着跟踪帧数的增加, 由于目标模型和分类器不更新造成的累积误差以及目标形变和视角变化导致不

更新的跟踪方法出现尺度计算偏差, 并且这种偏差由于不进行更新而不能修复, 所以会一直延续下去并且偏差越来越大, 而采用本文方法进行更新的方法则未出现这样的偏差, 并且对于目标的形变、视角变化、尺度变化有很好的鲁棒性(如图4(f), (g), (h), (i), (j)所示). 可见对于长期稳定的目标跟踪, 目标更新是必不可少的.

关于运行时间, 第一部分实验中不进行更新的目标跟踪方法平均运行时间为50 ms, 跟踪方法相同, 进行更新的跟踪方法平均运行时间为55 ms, 由此可见本文的方法对于整体跟踪的运行时间不会有太大影响.




图4 实验一的部分实验结果 (a)—(j) 分别是第2, 24, 35, 55, 62, 100, 104, 108, 130, 140 帧的实验结果

第二部分对比实验仍然采用行人的视频录像, 与当前比较流行、效果较好的Online Boost^[26], Semi-Boost^[27], MIL^[28], coGD^[29]算法以及不进行更新的随机森林分类器算法进行对比, 这五种算法的跟踪结果在图中分别用青色、蓝色、黄色、黑色和绿色, 本文算法为粉色. 每帧大小为 320×240 , 共140帧, 目标为一位行人, 占 22×36 个像素, (如图5(a)所示), 视频特点在上一部分实验中已经描述此处不再赘述.

从实验结果来看, 对于视频中的相似目标对Online Boost和Semi-Boost算法的效果影响较大, 跟踪过程中反复出现跟踪错误(如图5(b), (c), (d), (e), (l), (n)所示), 当目标尺度和视角变化时, MIL

算法出现了跟踪错误(如图5(f), (i), (j), (l), (m), (n), (o)所示), 也出现了一些尺度错误(如图5(g), (k)所示); CoGD算法在跟踪过程中相对稳定, 也出现了一些尺度错误(如图5(h), (j), (m), (o)所示), 本文算法跟踪稳定.

为说明本文算法的定位精度, 采用手动标记目标的真实位置并逐帧计算两种算法得到的跟踪结果与真实位置的重叠率overlap, 其公式如下:

$$\text{overlap} = \frac{\sum_2 I}{\sum_1 I + \sum_3 I - \sum_2 I}, \quad (8)$$

公式中 $\sum_1 I$ 和 $\sum_3 I$ 分别为图像块1和图像块3的像素和, $\sum_2 I$ 为图像块1和图像块3的重叠区域图像块2的像素和, 如图6示意图所示.



图5 实验二的部分实验结果 (a)—(o) 分别是第 3, 4, 9, 23, 35, 47, 59, 90, 91, 97, 103, 105, 114, 122, 140 帧的实验结果




图6 重叠率示意图

图7为第二部分实验的跟踪到的目标区域与真实位置的重叠率曲线图,可见本文算法的检测精度优于其他对比算法.

第三部分对比实验采用汽车拉力赛的视频录像,仍然与当前比较流行、效果较好的Online Boost^[26], Semi-Boost^[27], MIL^[28], coGD^[29]算法以及不进行更新的随机森林分类器算法进行对比,这五种算法的跟踪结果在图中也分别用青色、蓝色、黄色、黑色和绿色,本文算法为粉色.每帧大小为 291×180 ,共964帧,目标为一辆黑色越野车(大小为 55×44),视频较长,可体现出长期跟

踪,中间有部分及全部阻塞、模糊、尺度变化、光照变化、旋转等复杂情况,对本文算法的目标更新能力有了很好的测试,目标外观变化多样,对鲁棒性能很高要求.从实验结果来看,越野车的运动速度较快,出现了不同程度的模糊(如图8(a), (m), (o), (s)所示)本文算法由于采用学习的方法不断更新目标模型和分类器能够很好的适应目标的外观变化,而采用同样的分类器未使用本文方法进行更新的目标跟踪算法TT对于模糊情况出现跟丢现象, MIL算法、Semi-Boost算法、Online Boost算法对于这种模糊也都出现了目标跟丢现象;从图8(b)中可以看出随着目标的变化MIL算法出现跟踪框漂移现象;而当目标尺度发生变化时,如图8(c)所示,未进行更新的算法(绿色框)出现尺度错误,跟踪框变大;当有相似目标出现时(如图8(d), (g)所示)Semi-Boost出现了跟踪错误;当出现全部遮挡时(如图8(e), (k), (n)所示)MIL算法、Online Boost算法、coGD算法、Semi-Boost算法均出现了误检,而当目标重新出现时(如图9(f), (l), (o)所示)本文方法能够适应目标的外观变化并迅速检测到目标;对于尺度变化(如图8(g), (h),

(m), (o), (q) 所示)、部分遮挡(如图 8(p) 所示)及光照变化(如图 8(j), (t) 所示)本文方法有很好的鲁棒性, 其他对比方法均出现了不同程度的错误甚至丢失; 对于图像中出现的多个相似目标(如图 8(b), (c), (d), (g), (r) 所示)的情况, 本文均能够准确跟

踪目标, 可见本文算法具有在复杂背景下多目标的准确判别能力.

图 9 为第三部分实验的检测区域与真实位置的重叠率曲线图, 可见本文算法的检测精度整体上优于其他对比算法.




图 7 (网刊彩色) 第二部分实验的跟踪到的目标区域与真实位置的重叠率曲线图




图 8 实验三的部分实验结果 (a)—(t) 分别是第 2, 42, 99, 154, 166, 223, 242, 316, 321, 353, 367, 388, 408, 421, 596, 633, 660, 856, 903, 964 帧的实验结果




图9 (网刊彩色) 第三部分实验的检测区域与真实位置的重叠率曲线图

5 结 论

本文针对长期稳定的目标跟踪中的目标形变、尺度缩放、旋转等问题, 提出一种步步为营的反馈式学习方法, 该方法通过正、负约束实现对于目标模型和分类器的判别能力和容错能力提高的同时, 使更新带来的误差尽量小, 并证明了其收敛性. 通过实验表明, 对于同一种跟踪算法使用本文提出的目标更新方法进行更新学习的比不更新学习的跟踪效果要稳定得多, 对于目标的尺度变化、形变、旋转、视角变化、模糊等都有较好的适应性, 并通过与现有的较流行的方法进行比较, 本文方法鲁棒性较好并且提高了跟踪的精度, 有较高的研究和应用价值.

参考文献

- [1] Li T W, Shi A G, He S H 2009 *Acta Phys. Sin.* **58** 794 (in Chinese) [李天伟, 石爱国, 何四华 2009 物理学报 **58** 794]
- [2] Guo G R, Wang H Q, Jiang B 2006 *Acta Phys. Sin.* **55** 3985
- [3] Wang M W, Zhai H C, Gao L J 2009 *Acta Phys. Sin.* **58** 1662 (in Chinese) [王明伟, 翟宏琛, 高丽娟 2009 物理学报 **58** 1662]
- [4] Zhang J S, Zhang Z T 2010 *Chinese Phys. B* **19** 104601
- [5] Sun J F, Wang Q, Wang L 2010 *Chinese Phys. B* **19** 104203
- [6] Chen G Y, Guo Z X, Zhang C P 2003 *Chin. Phys. Lett.* **20** 2161
- [7] Wang L J, Jia S M, Wang S, Li Z X 2013 *Opt. Precision Eng.* **21** 2364 (in Chinese) [王丽佳, 贾松敏, 王爽, 李秀智 2013 光学精密工程 **21** 2364]
- [8] Zhu Q P, Yan J, Zhang H 2013 *Opt. Precision Eng.* **21** 437 (in Chinese) [朱秋平, 颜佳, 张虎 2013 光学精密工程 **21** 437]
- [9] Chen D C, Zhu M, Gao W, Sun H H, Yang W B 2014 *Opt. Precision Eng.* **22** 1661 (in Chinese) [陈东成, 朱明, 高文, 孙宏海, 杨文波 2014 光学精密工程 **22** 1661]
- [10] Ma Y, Lv Q B, Liu Y Y, Qian L L, Pei L L 2013 *Acta Phys. Sin.* **62** 204202 (in Chinese) [马原, 吕群波, 刘扬阳, 钱路路, 裴琳琳 2013 物理学报 **62** 204202]
- [11] Duarte M F, Baraniuk R G 2012 *IEEE Trans. Image Proc.* **21** 494
- [12] Sun X Y, Chang F L 2013 *Opt. Precision Eng.* **21** 3191 (in Chinese) [孙晓燕, 常发亮 2013 光学精密工程 **21** 3191]
- [13] Song S, Zhang B, Yin C L 2014 *Opt. Precision Eng.* **22** 1037 (in Chinese) [宋策, 张葆, 尹传历 2014 光学精密工程 **22** 1037]
- [14] Grabner H, Bischof H 2006 *CVPR* **2**
- [15] Avidan S 2007 *PAMI* **29** 261
- [16] Collins R, Liu Y, 2005 *PAMI* **27** 1631
- [17] Lim J, Ross D, Lin R, Yang M 2005 *NIPS* **2** 7
- [18] Yu Q, Dinh T, Medioni G 2008 *ECCV* **3** 6
- [19] Kalal Z, Matas J, Mikolajczyk K 2010 *Conference on Computer Vision and Pattern Recognition, CVPR*, San Francisco, CA, USA
- [20] Zhang T, Oles F J 2000 *Proceedings of 17th International Conference on Machine Learning*. Stanford 2000 p1191
- [21] Nigam K, McCallum A, Thrun S, Mitchell T 2000 *Machine Learning* **39** 103
- [22] Blum A, Mitchell T 1998 *COLT* **1** 2
- [23] Xu Q, Hu D H, Xue H 2009 *BMC Bioinformatics* **10** S47
- [24] Viola P, Jones M, Snow D 2005 *International Journal of Computer Vision* **63** 153
- [25] Breiman L 2001 *Machine Learning* **45** 5
- [26] Lepetit V, Fua P 2006 *IEEE Trans. Pattern Analysis and Machine Intelligence* **28** 1465

- [27] Grabner H, Leistner C, Bischof H 2008 *European Conf. on Computer Vision* DC 2009 p983
 [28] Babenko B, Yang M H, Belongie S 2009 *IEEE Conf. on Computer Vision and Pattern Recognition*, Washington, [29] Yu Q, Dinh T B, Medioni G 2008 *European Conf. on Computer Vision* 2008

Research on semi-supervising learning algorithm for target model updating in target tracking*

Gao Wen^{1)2)†} Tang Yang¹⁾ Zhu Ming¹⁾²⁾

1) (Changchun Institute of Optics, Fine Mechanics and Physics, Chinese Academy of Sciences, Changchun 130033, China)

2) (Key Laboratory of Airborne Optical Imaging and Measurement, Chinese Academy of Sciences, Changchun 130033, China)

(Received 17 April 2014; revised manuscript received 19 May 2014)

Abstract

Target detection and tracking technique is one of the hot subjects in image processing and computer vision fields, which has significant research value not only in military areas such as imaging guidance and military target tracking, but also for civil use such as security and monitoring and the intelligent man-machine interaction. In this paper, for target deformation, scale changing, rotation, and other issues in the long-term stable target tracking, a bootstrapping feedback learning algorithm is proposed, which may improve the target model and the classifier discriminating capacity as well as the fault tolerance ability; and it also makes fewer errors during the updating, and then the proof of convergence of the algorithm is given. Experimental results show that among the same tracking algorithms, utilization of the learning method to update the target model and classifier is more stable and more adaptable than using it in the processes of target scale changing, deformation, rotation, perspective changing and fuzzy. And compared with the existing conventional method, this method has a better robustness, and a high value in practical application and research.

Keywords: target tracking, target model update, semi-supervising learning, classification

PACS: 42.30.Va, 42.30.Tz, 07.05.Pj, 02.50.-r

DOI: 10.7498/aps.64.014205

* Project supported by the Key Laboratory of Airborne Optical Imaging and Measurement, Chinese Academy of Sciences (Grant No. Y2HC1SR121).

† Corresponding author. E-mail: cwenzi@126.com