



(12) 发明专利申请

(10) 申请公布号 CN 104915970 A

(43) 申请公布日 2015. 09. 16

(21) 申请号 201510326021. 7

(22) 申请日 2015. 06. 12

(71) 申请人 南京邮电大学

地址 210023 江苏省南京市栖霞区文苑路 9 号

(72) 发明人 朱松豪 师哲 胡学伟

(74) 专利代理机构 南京知识律师事务所 32207

代理人 汪旭东

(51) Int. Cl.

G06T 7/20(2006. 01)


权利要求书2页 说明书8页 附图5页

(54) 发明名称

一种基于轨迹关联的多目标跟踪方法

(57) 摘要

本发明公开了一种基于轨迹关联的多目标跟踪方法,该方法包括以下步骤:首先,基于场景自适应方法生成局部轨迹,实现检测响应与原有轨迹关联;然后,基于增量线性判决的表观模型,实现全局轨迹关联;最后,基于非线性运动模型,实现轨迹片段间空缺填补,以获取完整且平滑的跟踪轨迹。本发明的方法能在目标遮挡、不同目标具有相似外貌特征、运动目标方向突变等复杂情况下,实现多目标的正确关联,最终得到稳定、连续的跟踪轨迹。



1. 一种基于轨迹关联的多目标跟踪方法,其特征在于,所述方法包括如下步骤:

步骤 1:基于场景自适应方法生成局部轨迹,实现检测响应与原有轨迹关联;

步骤 2:基于增量线性判决的表观模型,实现全局轨迹关联;

步骤 3:基于非线性运动模型,实现轨迹片段间空缺填补,以获取完整且平滑的跟踪轨迹。

2. 根据权利要求 1 所述的一种基于轨迹关联的多目标跟踪方法,其特征在于:所述步骤 1 基于场景自适应方法生成局部轨迹,实现检测响应与原有轨迹关联,包括:

利用前景检测技术实现图像目标的检测;基于场景自适应计算检测响应与已有轨迹间的关联性;判断检测响应是否成功关联某条轨迹;将成功关联的检测响应加入目标集合中,同时将未关联的检测响应作为新目标加入目标集合中。

3. 根据权利要求 1 所述的一种基于轨迹关联的多目标跟踪方法,其特征在于,所述方法的局部轨迹关联,包括:

定义 $D = \{d_i\}$ 为一系列检测响应,通过计算相似性得到目标的轨迹片段:

$$P_{link} = A_{pos}(d_j|d_i)A_{size}(d_j|d_i)A_{appr}(d_j|d_i) \quad (1)$$

上式中的 $A_{pos}(d_i|d_2)$ 表示不同目标间位置的相似性:

$$A_{pos}(d_1|d_2) = \exp\left[-\frac{(x_1-x_2)^2}{\sigma_x^2}\right]\exp\left[-\frac{(y_1-y_2)^2}{\sigma_y^2}\right] \quad (2)$$

上式中的 x_1 、 y_1 与 x_2 、 y_2 分别为不同目标在连续两帧中的位置, σ_x 与 σ_y 分别为当前轨迹片段的方差,式 (1) 中的 $A_{size}(d_i|d_2)$ 表示目标尺寸的相似性:

$$A_{size}(d_1|d_2) = \exp\left[-\frac{(s_1-s_2)^2}{\sigma_s^2}\right] \quad (3)$$

上式中的 s_1 与 s_2 分别为目标的尺寸, σ_s 为当前所有轨迹片段面积的方差;

式 (1) 中的 $A_{appr}(d_i|d_2)$ 表示目标间的表观相似性:

$$A_{appr}(d_1|d_2) = \sqrt{1 - BC(d_1, d_2)} \\ = \sqrt{1 - \sum_{n=1}^N \sqrt{q_{(d_1)_n} p_{(d_2)_n}}} \quad (4)$$

上式中的 q 、 p 分别表示不同目标灰度级的权重, N 表示直方图的级数;

采用基于场景自适应的关联策略,将当前检测响应关联成局部轨迹:

$$A_{f_k}(d_i, T_j) = G(Dist_{f_k}(d_i(t), T_j); u_{f_k}, s_{f_k}^2) \quad (5)$$

$$A_{f_k}(d_i, T_j) = G(Dist_{f_k}(d_i(t), T_j); u_{f_k}, s_{f_k}^2) \quad (6)$$

4. 权利要求 1 所述的一种基于轨迹关联的多目标跟踪方法,其特征在于,所述步骤 2 基于增量线性判决的表观模型,实现全局轨迹关联包括:运动模型、时域模型与表观模型在内的三个相似性模型;采用基于学习的表观模型更新策略:首先,从之前运动轨迹中提取在线训练样本;然后,基于增量线性判决法,将目标轨迹的表观信息投影到判决空间。

5. 权利要求 1 或 4 所述的一种基于轨迹关联的多目标跟踪方法,其特征在于,所述步骤 2 基于增量线性判决的表观模型,实现全局轨迹关联全局轨迹关联的具体过程如下:

计算轨迹间的相似性：

$$P_{link}(T_j^L | T_i^L) = A_a(T_j^L | T_i^L) A_m(T_j^L | T_i^L) A_t(T_j^L | T_i^L) \quad (7)$$

基于运动模型,计算轨迹间的运动相似性：

$$A_m(T_j^L | T_i^L) = G(p_i^{tail} + v_i^{tail} \Delta t; p_j^{head}; \Sigma_{\Delta t}) \cdot G(p_j^{head} - v_j^{head} \Delta t; p_i^{tail}; \Sigma_{\Delta t}) \quad (8)$$

上式中的 Δt 表示第 i 条轨迹 T_i 的尾部与第 j 条轨迹 T_j 的头部间的帧数; p 和 v 表示经卡尔曼滤波后目标轨迹的位置与速度信息；

时域模型保证了两条轨迹 T_i 与 T_j 在时间上没有重叠：

$$P_i(T_i, T_j) = \begin{cases} 1 & \text{if } f_{j(s)} - f_{i(e)} > 0 \\ 0 & \text{otherwise} \end{cases} \quad (9)$$

上式中的 $f_i(e)$ 表示第 i 轨迹 T_i 的结束帧, $f_j(s)$ 表示第 j 轨迹 T_j 的起始帧；基于增量线性表观模型 Λ , 计算轨迹间的表观相似性：

$$\Lambda^A(X, Y) = \frac{(U^T f(X) \bullet U^T f(Y))}{\|U^T f(X)\| \|U^T f(Y)\|} \quad (10)$$

6. 根据权利要求 1 所述的一种基于轨迹关联的多目标跟踪方法,其特征在于,所述步骤 3 基于非线性运动模型,实现轨迹片段间空缺填补,以获取完整且平滑的跟踪轨迹,包括：

分析新生成的轨迹 T_i^* :如果该轨迹为一单独轨迹,则将其归入最终的轨迹集合 $\{T_i\}$;如果该轨迹包含两条以上的轨迹片段,则进入下一步；

按时间先后顺序,排列轨迹 T_i^* 对应的轨迹片段,并填补片段间的空缺:对由于目标遮挡引起的轨迹片段,采用线性运动模型进行填补;对由于运动状态突变引起的轨迹片段,采用非线性运动估计模型进行填补；

重复上述步骤,遍历轨迹集合 $\{T_i^*\}$ 中每一条轨迹,剔除未能成功关联的轨迹片段,最终得到目标平滑而连续的轨迹。

一种基于轨迹关联的多目标跟踪方法

技术领域

[0001] 本发明涉及一种多目标跟踪方法,尤其涉及一种基于轨迹关联的多目标跟踪方法,属于图像处理技术领域。

背景技术

[0002] 基于轨迹关联的多目标跟踪算法是国内外学者的研究热点,其主要原理是在跟踪目标的多个短小跟踪片段间建立关联,以获取跟踪目标连续、平滑的跟踪轨迹。多目标跟踪算法的关键在于如何度量轨迹间的相似性。

[0003] 在复杂场景中,当具有相似表观的目标间存在交互行为时,很易导致错误的轨迹关联。这就要求多目标跟踪算法不仅能准确跟踪新出现的目标,还能对原有的跟踪目标保持连续性。此外,基于在线学习表观模型算法虽然能满足时性需求,但这种方法需要整个视频序列的先验信息,且迭代过程加大了方法的时间复杂度;同时,由于跟踪目标运动的任意性,导致运动轨迹的非线性。而本发明能够很好地解决上面的问题。

发明内容

[0004] 本发明目的在于解决了复杂场景中具有相似表观的目标间存在交互行为时,很易导致错误的轨迹关联的问题,提出了一种基于轨迹关联的多目标跟踪方法,该方法是基于场景自适应的局部轨迹生成方法。

[0005] 本发明解决其技术问题所采取的技术方案是:一种基于轨迹关联的多目标跟踪方法,该方法包括如下步骤:

[0006] 步骤1:基于场景自适应方法生成局部轨迹,实现检测响应与原有轨迹关联;

[0007] 步骤2:基于增量线性判决的表观模型,实现全局轨迹关联;

[0008] 步骤3:基于非线性运动模型,实现轨迹片段间空缺填补,以获取完整且平滑的跟踪轨迹。

[0009] 进一步的,本发明局部轨迹生成的具体过程,包括:

[0010] 利用前景检测技术实现图像目标的检测;基于场景自适应计算检测响应与已有轨迹间的关联性;判断检测响应是否成功关联某条轨迹;将成功关联的检测响应加入目标集合中,同时将未关联的检测响应作为新目标加入目标集合中。

[0011] 进一步的,本发明局部轨迹关联的具体过程,包括:

[0012] 定义 $D = \{d_i\}$ 为一系列检测响应,通过计算相似性得到目标的轨迹片段:

[0013] $P_{link} = A_{pos}(d_j | d_i) A_{size}(d_j | d_i) A_{appr}(d_j | d_i)$ (1)

[0014] 上式中的 $A_{pos}(d_i | d_2)$ 表示不同目标间位置的相似性:

[0015] $A_{pos}(d_1 | d_2) = \exp[-\frac{(x_1 - x_2)^2}{\sigma_x^2}] \exp[-\frac{(y_1 - y_2)^2}{\sigma_y^2}]$ (2)

[0016] 上式中的 x_1 、 y_1 与 x_2 、 y_2 分别为不同目标在连续两帧中的位置, σ_x 与 σ_y 分别为当前轨迹片段的方差。式(1)中的 $A_{size}(d_1 | d_2)$ 表示目标尺寸的相似性:

$$[0017] \quad A_{size}(d_1|d_2) = \exp\left[-\frac{(s_1 - s_2)^2}{\sigma_s^2}\right] \quad (3)$$

[0018] 上式中的 s_1 与 s_2 分别为目标的尺寸, σ_s 为当前所有轨迹片段面积的方差。式 (1) 中的 $A_{appr}(d_1|d_2)$ 表示目标间的表观相似性:

$$[0019] \quad \begin{aligned} A_{appr}(d_1|d_2) &= \sqrt{1 - BC(d_1, d_2)} \\ &= \sqrt{1 - \sum_{n=1}^N \sqrt{q_{(d_1)_n} p_{(d_2)_n}}} \end{aligned} \quad (4)$$

[0020] 上式中的 q 、 p 分别表示不同目标灰度级的权重, N 表示直方图的级数。

[0021] 本发明采用基于场景自适应的关联策略, 将当前检测响应关联成局部轨迹:

$$[0022] \quad A_{f_k}(d_i, T_j) = G(\text{Dist}_{f_k}(d_i(t), T_j); u_{f_k}, s_{f_k}^2) \quad (5)$$

$$[0023] \quad A_{f_k}(d_i, T_j) = G(\text{Dist}_{f_k}(d_i(t), T_j); u_{f_k}, s_{f_k}^2) \quad (6)$$

[0024] 进一步的, 本发明全局轨迹关联的具体过程, 包括:

[0025] 计算轨迹间的相似性:

$$[0026] \quad P_{link}(T_j^L | T_i^L) = A_u(T_j^L | T_i^L) A_m(T_j^L | T_i^L) A_t(T_j^L | T_i^L) \quad (7)$$

[0027] 进一步的, 本发明基于运动模型, 计算轨迹间的运动相似性, 包括:

$$[0028] \quad \begin{aligned} A_m(T_j^L | T_i^L) &= G(p_i^{tail} + v_i^{tail} \Delta t; p_j^{head}; \Sigma_{\Delta t}) \\ &\quad \bullet G(p_j^{head} - v_j^{head} \Delta t; p_i^{tail}; \Sigma_{\Delta t}) \end{aligned} \quad (8)$$

[0029] 上式中的 Δt 表示第 i 条轨迹 T_i 的尾部与第 j 条轨迹 T_j 的头部间的帧数; p 和 v 表示经卡尔曼滤波后目标轨迹的位置与速度信息。

[0030] 时域模型保证了两条轨迹 T_i 与 T_j 在时间上没有重叠:

$$[0031] \quad P_i(T_i, T_j) = \begin{cases} 1 & \text{if } f_{j(s)} - f_{i(e)} > 0 \\ 0 & \text{otherwise} \end{cases} \quad (9)$$

[0032] 上式中的 $f_{i(e)}$ 表示第 i 轨迹 T_i 的结束帧, $f_{j(s)}$ 表示第 j 轨迹 T_j 的起始帧。

[0033] 基于增量线性表观模型 Λ , 计算轨迹间的表观相似性:

$$[0034] \quad \Lambda^A(X, Y) = \frac{(U^T f(X) \bullet U^T f(Y))}{\|U^T f(X)\| \|U^T f(Y)\|} \quad (10)$$

[0035] 进一步的, 本发明轨迹间空缺填补计算步骤如下:

[0036] 步骤 1: 分析新生成的轨迹 T_i^* : 如果该轨迹为一单独轨迹, 则将其归入最终的轨迹集合 $\{T_i\}$; 如果该轨迹包含两条以上的轨迹片段, 则进入下一步。

[0037] 步骤 2: 按时间先后顺序, 排列轨迹 T_i^* 对应的轨迹片段, 并填补片段间的空缺: 对于由于目标遮挡引起的轨迹片段, 本发明采用线性运动模型进行填补; 对于由于运动状态突变引起的轨迹片段, 本发明采用非线性运动估计模型进行填补。

[0038] 步骤 3: 重复以上步骤, 遍历轨迹集合 $\{T_i^*\}$ 中每一条轨迹, 剔除未能成功关联的轨迹片段, 最终得到目标平滑而连续的轨迹。

附图说明

[0039] 图 1 为基于 MF1-c1 视频片段的跟踪结果示意图。

[0040] 图 2 为基于 S2L1 视频库的跟踪结果示意图。

[0041] 图 3 为基于本发明的目标跟踪结果示意图。

[0042] 图 4 为本发明的方法流程图。

具体实施方式

[0043] 下面结合说明书附图对本发明创造作进一步的详细说明。

[0044] 如图 4 所示,本发明的提供了一种基于轨迹关联的多目标跟踪方法,该方法包括:首先,场景自适应的局部轨迹生成方法能自适应地选取合适特征表征目标,且通过特征融合减少目标表征的二义性;其次,采用基于增量线性判决的表观模型可有效减少计算量,且可有效解决目标在显著形变、表观改变及长时遮挡下的识别问题;同时,采用基于非线性运动模型的轨迹填充策略,可有效解决不满足线性运动轨迹间的关联问题,以生成更为平滑、连续的跟踪轨迹。

[0045] 步骤 1:基于场景自适应方法生成局部轨迹,实现检测响应与原有轨迹关联。

[0046] 鲁棒性的目标表示,是目标局部轨迹生成过程中的一个重要任务。为解决此类问题,本发明提出了基于场景自适应的局部轨迹生成方法,即:依据分层的特征空间,自适应地分阶关联局部轨迹。

[0047] 1、基于场景自适应的局部轨迹思路

[0048] 在多目标关联框架中,一个关键步骤是将当前帧的 n 个检测响应与 m 条轨迹进行关联。假设 $D^t := \{d_1, d_2, \dots, d_n\}$ 表示第 t 帧中的 n 个检测响应, $T := \{T_1, T_2, \dots, T_m\}$ 表示 m 条轨迹, $T_j := \{\dots, d_j^{(t)}, d_j^{(t+1)}, \dots\}$ 表示与第 j 条轨迹 T_j 相关联的检测响应, $d_j^{(t)}$ 表示 t 时刻与轨迹 T_j 关联的检测响应。

[0049] 轨迹间的相似性常常是先计算检测响应与轨迹间基于某个特征的相似性,然后将不同特征的相似性相乘以获得最终的关联性:

$$P_{\text{link}}(d_i, T_j) = A_{\text{pos}}(d_i, T_j) A_{\text{sz}}(d_i, T_j) A_{\text{appr}}(d_i, T_j) \dots \quad (11)$$

[0051] 上式中的这里 A 定义了检测响应 d_i 与轨迹 T_j 间的相似性, $f(k)$ 定义了目标响应的特征。然而,基于众多特征的相似性关联计算,不能提高目标识别的准确性;相反,它易导致算法的错误率叠加和时间复杂度的增大。为解决该问题,本发明提出基于场景自适应分层空间的关联。

[0052] 2、场景自适应分层空间的关联

[0053] 首先建立一个特征空间 F ,用以描述检测响应与轨迹间的相似性:

$$P_{\text{link}}(d_i, T_j | F) = \prod_{f(k) \in F} A_{f(k)}(d_i, T_j) \quad (12)$$

[0055] 然后,依据特征空间 F 重构 K 层特征空间:利用鲁棒性的特征,构建特征空间的低层;通过逐渐添加特征,构建特征空间的高层:

$$F_{H_k} = F_{H_{k-1}} \cup \{f(k)\}。 \quad (13)$$

[0057] 3、基于场景自适应的特征选取过程

[0058] 假设 $d_i^{(t)}$ 表示第 t 帧中的检测响应 d_i , T_j 表示一系列在第 t 帧前已关联到目标 j 的轨迹, 则当检测响应 d_i 在第 t 帧时已关联到 T_j 情况下, 目标 j 特征表示的差异值为:

$$[0059] \quad v_{f(k)}^j(t) = \text{Dist}_{f(k)}(d_i^{(t)}, T_j) \quad (14)$$

[0060] 上式中的 $\text{Dist}_{f(k)}$ 表示检测响应 d_i 与轨迹 T_j 在特征表示 $f(k)$ 下的距离度量。

[0061] 分别计算差异值 $v_{f(k)}^j(t)$ 的均值 $u_{f(k)}$ 与标准偏差 $S_{f(k)}$:

$$[0062] \quad \begin{cases} u_{f(k)} = \frac{\sum_{j=1}^{N_f} \sum_{l=1}^t \delta_j(l) v_{f(k)}^j(l)}{\sum_{j=1}^{N_f} \sum_{l=1}^t \delta_j(l) + 1} \\ s_{f(k)} = \left(\frac{\sum_{j=1}^{N_f} \sum_{l=1}^t (\delta_j(l) v_{f(k)}^j(l))^2 - (u_{f(k)})^2}{\sum_{j=1}^{N_f} \sum_{l=1}^t \delta_j(l) + 1} \right)^{\frac{1}{2}} \end{cases} \quad (15)$$

[0063] 上式中的 N_f 表示关联到轨迹的检测响应数目, $\delta_j^{(t)}$ 为:

$$[0064] \quad \delta_j^{(t)} = \begin{cases} 1 & f_k \text{ is selected to represent } r_j^{(t)} \text{ on frame } t \\ 0 & \text{otherwise} \end{cases} \quad (16)$$

[0065] 目标特征 $f(k)$ 的鲁棒性表示为:

$$[0066] \quad R_k = U_k \left(w_1 \bullet \frac{1}{u_{f(k)}} + w_2 \bullet \frac{1}{s_{f(k)}} \right) \quad (17)$$

[0067] 上式中的 U_k 是一个为不同特征预先设定的参数 (本发明设为 20), w_1 与 w_2 是权重参数。

[0068] 实际应用中, 本发明采用迭代方式更新 $u_{f(k)}$ 与 $S_{f(k)}$:

$$[0069] \quad \hat{u}_{f(k)} = \left(1 - \frac{1}{\Delta_n(t) + 1} \right) \bullet u_{f(k)} + \frac{1}{\Delta_n(t) + 1} \bullet v_{f(k)}^j(t+1) \quad (18)$$

$$[0070] \quad (\hat{s}_{f(k)})^2 = \left(1 - \frac{1}{\Delta_n(t) + 1} \right) \bullet (s_{f(k)})^2 + \frac{1}{\Delta_n(t) + 1} \bullet (u_{f(k)}^2 - \hat{u}_{f(k)}^2 + (v_{f(k)}^j(t+1))^2) \quad (19)$$

[0071] 上式中的 $\Delta_n(t)$ 为:

$$[0072] \quad \Delta_n(t) = \sum_{j=1}^{N_f} \sum_{l=1}^t \delta_j(l) \quad (20)$$

[0073] 对于给定的更新值 $u_{f(k)}$ 与 $S_{f(k)}$, R_k 可通过式 (17) 进行更新。

[0074] 4、基于场景自适应的局部轨迹

[0075] 假设选取 K 个鲁棒性特征, 构建 K 层特征空间 H_k , 且在 H_k 内有 M_k 条轨迹 $T_{hk} := \{T_{hk}^j\}_M$ 与 N_k 个检测响应 $D_{hk} := \{d_{hk}^i\}_N$ 间存在关联, 则基于场景自适应的局部轨迹具体过程描述如下:

[0076] 计算 T_{hk} 与 D_{hk} 之间的相似性矩阵 M_{hk} :

$$[0077] \quad A_{H_k}^{ij} = P_{link}(d_i, T_j | F_{H_k}) = \prod_{f(k) \in F_{H_k}} A_{f(k)}(d_i, T_j) \quad (21)$$

[0078] 上式中的 A_{hk}^{ij} 表示 M_{hk} 的第 i 行和第 j 列的元素, 且

$$[0079] \quad A_{f(k)}(d_i, T_j) = G(\text{Dist}_{f(k)}(d_i(t), T_j); u_{f(k)}, s_{f(k)}^2) \quad (22)$$

[0080] 基于式 (21) 所示的相似性矩阵, 本发明提出基于分层的局部轨迹生成方法, 该方法首先检测响应, 并以此更新轨迹 T_j ; 然后, 对那些不可靠连接, 将构建多层特征空间; 最后, 采用迭代过程实现轨迹关联, 对那些由于目标遮挡、走出区域而引起的目标跟丢, 则在全局轨迹关联算法框架中进行进一步分析。

[0081] 步骤 2: 基于增量线性判决的表观模型, 实现全局轨迹关联;

[0082] 本发明提出基于增量线性判别表观模型的在线学习关联策略。由于增量线性判别法不仅有利于减少表观模型学习的计算量, 且有利于长时保存轨迹信息, 因此, 该关联策略可有效解决显著形变、表观改变、长时遮挡下的目标识别问题。

[0083] 1、训练样本

[0084] 由于遮挡导致、显著形变、表观改变等情况会产生伪轨迹, 因此, 本发明只从已有轨迹片段中提取训练样本。

[0085] 训练样本的生成过程是: 首先将每帧图像中的检测相应用 HSV 色彩空间的特征 f_i 表示, 然后与标记轨迹片段 y_i 生成 $B = \{(f_i, y_i)\}$ 。为提高目标识别的效果, 本发明基于增量线性判决分析法实现高维特征的低维空间投影。

[0086] 2、增量线性判决分析法

[0087] 为确保同类数据间的高相似性, 及不同类数据间的高差异性, 基于类分离最大化原则构建如下式所示的投影矩阵:

$$[0088] \quad \hat{U} = \arg \max_U \frac{|U^T S_B U|}{|U^T S_T U|} \quad (23)$$

[0089] 上式中的 S_T 和 S_B 分别表示总体散度和类间散度:

$$[0090] \quad \begin{cases} S_T = \sum_l (f_l - \mu) \cdot (f_l - \mu)^T \\ S_B = \sum_{i=1}^C (m_i - \mu)(m_i - \mu)^T \end{cases} \quad (24)$$

[0091] 上式中的 C 表示轨迹片段的数目, n_i 表示第 i 类轨迹的片段数, m_i 表示第 i 类轨迹的平均特征值, μ 表示所有轨迹的平均特征值。

[0092] 利用特征值分解, 分别获得 S_T 和 S_B 的主成分, 及相应的生成空间; 对新产生的轨迹片段, 同样利用特征值分解, 获得其主成分及相应的生成空间。

[0093] 第 i 类轨迹的特征模型表示为:

$$[0094] \quad \{\mu_i, n_i, P_i, \Lambda_i\} \quad (25)$$

[0095] 上式中的 P_i 表示第 i 类轨迹的主成分, Λ_i 表示第 i 类轨迹的生成空间。

[0096] 为提高计算效率, 本发明采用不同轨迹间基向量的线性组合表示轨迹关联后的主成分:

$$[0097] \quad P_3 = h([p_1, p_2, \mu_1 - \mu_2]) \cdot R \quad (26)$$

[0098] 上式中的 $h(\cdot)$ 表示对向量进行正交归一化处理, R 为旋转矩阵。

[0099] 基于以上公式, 轨迹关联后的总体散度矩阵 S_T 可表示为:

[0100] $S_{E_3} = h([P_1, P_2, \mu_1 - \mu_2]) \bullet R \bullet \Lambda_3 \bullet R^T \bullet h([P_1, P_2, \mu_1 - \mu_2])^T$ (27)

[0101] 由于正交性, 上式可进一步表示为:

[0102] $h([P_1, P_2, \mu_1 - \mu_2])^T \bullet S_{E_3} \bullet h([P_1, P_2, \mu_1 - \mu_2]) = R \bullet \Lambda_3 \bullet R^T$ (28)

[0103] 上式等号左边的表达式可确定旋转矩阵 R 及相应的主成分 P_3 , 及获得轨迹合并后的生成空间 Λ_3 。

[0104] 在本发明中, 轨迹 i 和轨迹 j 的类间散度矩阵 S_b 的空间模型表示为:

[0105] $\{\mu_{ij}, n_i, Q_i, \Delta_i, n_{ij}, \alpha_{ij}\}$ (29)

[0106] 上式中的 Q_i 表示第 i 条轨迹的主成分, Δ_i 为第 i 条轨迹的生成空间, α_{ij} 表示轨迹 i 与轨迹 j 的特征均值在投影算子 Q 下的特征均值。利用算子向量 α_{ij} 及轨迹 i 的总体样本均值 μ_i , 可得到轨迹集合的特征均值:

[0107] $\mu_{ij} = \mu_i + \alpha_{ij} \bullet Q_i$ (30)

[0108] 本发明利用下式表示轨迹合并后的类间散度:

[0109]
$$\begin{cases} S_{B_3} = S_{B_1} + S_{B_2} + A + (\mu_1 - \mu_2) \bullet (\mu_1 - \mu_2)^T \bullet n_1 n_2 / (n_1 + n_2) \\ A = \sum_{k=1,2} -(\mu_{2,k} - \mu_{1,k}) \bullet (\mu_{2,k} - \mu_{1,k})^T \bullet \frac{n_{1,k} n_{2,k}}{n_{1,k} + n_{2,k}} \end{cases}$$
 (31)

[0110] 上式中的 K 为轨迹片段的类标签。

[0111] 轨迹关联后的主成分求解问题可转化为求解旋转矩阵 R 的问题:

[0112] $h([Q_1, Q_2, \mu_1 - \mu_2])^T \bullet S_{B_3} \bullet h([Q_1, Q_2, \mu_1 - \mu_2]) = R \Lambda_3 R^T$ (32)

[0113] 第 i 类轨迹的特征均值 α_{ij} 表示轨迹 i 中所有片段特征均值的主成分投影:

[0114] $\alpha_{ij} = Q^T (\mu_{ij} - \mu_i)$ (33)

[0115] 此时, 轨迹 i 的特征均值更新为:

[0116] $\mu_{3j} = (n_{1j} \mu_{1j} + n_{2j} \mu_{2j}) / (n_{1j} + n_{2j})$ (34)

[0117] 基于类间散度特征模型获取投影算子的过程描述如下。

[0118] 投影空间表示为:

[0119] $\left[\left(P_3 \Delta_3^{-\frac{1}{2}} \right)^T, Q3 \right]$ (35)

[0120] 投影空间的基向量集合表示为:

[0121] $\Omega = h \left(\left[\left(P_3 \Delta_3^{-\frac{1}{2}} \right)^T, Q3 \right] \right)$ (36)

[0122] 旋转矩阵 R 表示为:

[0123] $\Omega^T \left(P_3 \Delta_3^{-\frac{1}{2}} \right)^T S_{B_3} \left(P_3 \Delta_3^{-\frac{1}{2}} \right)^T \Omega = R \Lambda R^T$ (37)

[0124] 投影算子 U 表示为:

$$[0125] \quad U = \left(P_3 \Delta_3^{-\frac{1}{2}} \right)^T \bullet W = \left(P_3 \Delta_3^{-\frac{1}{2}} \right)^T \bullet \Omega R \quad (38)$$

[0126] 基于增量线性判决的表现相似性模型表示为：

$$[0127] \quad \Lambda^A = (X, Y) = \frac{U^T f(X) \bullet U^T f(Y)}{\|U^T f(X)\| \|U^T f(Y)\|} \quad (39)$$

[0128] 步骤3：基于非线性运动模型，实现轨迹片段间空缺填补，以获取完整且平滑的跟踪轨迹

[0129] 1、轨迹关联

[0130] 假设轨迹中含有置信度较高（置信度评测标准参见实验部分）的轨迹片段集合为 $\{T_1^*, T_2^*, \dots, T_M^*\}$ ，且 T_i^* 的表达形式为：

$$[0131] \quad \{d_i^t, \dots, d_i^{t_e}\} \quad (40)$$

[0132] 上式中的 t_s^i 与 t_e^i 分别表示轨迹片段 i 的开始帧与结束帧。 $d_i^t = \{p_i^t, s_i^t, v_i^t\}$ 表示 t 时刻的检测响应， p_i^t 、 s_i^t 、 v_i^t 分别表示位置信息、尺寸信息、速度矢量信息。

$$[0133] \quad G(p^{\text{tail}} + v^{\text{tail}} \Delta t - p^{\text{head}}, \Sigma_p) G(p^{\text{head}} - v^{\text{head}} \Delta t - p^{\text{tail}}, \Sigma_p) \quad (41)$$

[0134] 上式中的 Δt 为 p^{tail} 与 p^{head} 的帧差， $G(\cdot)$ 为高斯函数。

[0135] 本发明只关联那些置信度较高的轨迹片段：首先，去除那些满足式 (41) 所示的线性运动模型的头部片段和尾部片段；然后，将那些满足非线性运动状态模型的片段，运用非线性运动模型进行关联。

[0136] 2、基于非线性运动模型的轨迹关联

[0137] 利用算法1，实现非线性运动轨迹片段的关联。

[0138]

算法1：基于非线性运动模型的轨迹关联

输入： 轨迹片段集合 $\{T_1^*, T_2^*, \dots, T_M^*\}$

初始化全局轨迹片段集 $M = \emptyset$

For $i=1, 2, \dots, n$ **do:**

● 如果 T_i^* 不符合线性运动模型，进入下一步。

● 初始化从开始帧 $t_s = t_e^i$ 到截止帧 $t_e = t_s^i$ 的非线性运动模型。

■ **For** $j=t_s^i+1, \dots, t_e^i$ **do:**

if $\langle v_j^i, (p_j^i, p_j^i) \rangle > \zeta$ then $t_s = j-1$, break

■ **For** $j=t_e^i-1, \dots, t_s^i$ **do:**

if $\langle v_j^i, (p_j^i, p_j^i) \rangle > \zeta$ then $t_e = j+1$, break


■ **If** $t_s < t_e \& \langle v_{t_s}^i, (p_{t_s}^i, p_{t_s}^i) \rangle > 2\zeta \& \langle v_{t_e}^i, (p_{t_e}^i, p_{t_e}^i) \rangle > 2\zeta$

then $M = M \cup \{T_i^*\}$, where $T_i^* = \{d_i^{t_s}, \dots, d_i^{t_e}\}$

输出： 轨迹集 M

[0139] 在上述算法1中， $\langle a, b \rangle$ 表示向量 a 、 b 的角度， (x, y) 表示 x 到 y 的向量， ζ 为角度阈值。上述的算法依据在线学习的非线性运动模型，利用检测响应关联轨迹，获取平滑、


连续的轨迹。相比之前的跟踪算法,该算法在目标运动方向突变跟踪性能上表现出一定的鲁棒性。



(a)




(b)



(c)

图 1



(a)



(b)





图 2



(a)



(b)



(c)



(d)

图 3




图 4