





**Incomplete Trajectory Classification and Prediction in  
Video Surveillance**

**By  
Lijin Pang**

**A Thesis Submitted to**

**University of Chinese Academy of Sciences**

**In partial fulfillment of the requirement**

**For the degree of**

**Master of Computer Technology**

**College of Engineering and Information Technology**

**University of Chinese Academy of Sciences**

**May, 2015**



## 中国科学院大学直属院系 研究生学位论文原创性声明

本人郑重声明：所呈交的学位论文是本人在导师的指导下独立进行研究工作所取得的成果。尽我所知，除文中已经注明引用的内容外，本论文不包含任何其他个人或集体已经发表或撰写过的研究成果。对论文所涉及的研究工作做出贡献的其他个人和集体，均已在文中以明确方式标明或致谢。

作者签名：

日 期：

## 中国科学院大学直属院系 学位论文授权使用声明

本人完全了解并同意遵守中国科学院有关保存和使用学位论文的规定，即中国科学院有权保留送交学位论文的副本，允许该论文被查阅，可以公布该论文的全部或部分内容，可以采用影印、缩印或其他复制手段保存、汇编本学位论文。

涉密的学位论文在解密后适用本声明。

作者签名：

日 期：

导师签名：

日 期：



## 摘 要

智能视频监控是计算机视觉研究中很重要的一个应用领域。对智能监控视频中运动目标进行行为分析、异常检测，并预测目标将来的运动行为具有广泛的应用前景。行为模式分析是异常检测和行为预测的一个重要方法。监控场景中的大部分目标按照一定的行为模式运动而不是随意走动，这些行为模式的信息可用于检测目标的异常行为和行为预测。本文以此为研究内容，具有重要的理论意义和应用价值。

在实际监控场景中, 由于跟踪故障、遮挡等原因使得目标跟踪时得到大量的不完整轨迹。在目标行为分析基础上, 针对监控场景中这些不完整轨迹预测的问题, 用历史轨迹数据学习运动模型 (即行为模式), 通过建立当前轨迹数据与历史观测数据之间的函数映射关系, 不仅能预测目标将来的运动行为, 还能判断目标行为, 进行异常行为检测。在很多监控场景中, 轨迹预测能够减少安全隐患, 并作最优路线指导, 有着重要的研究意义。

本文基于三次 **B** 样条控制点对轨迹进行表示, 根据不完整轨迹与稀疏重构分析方法求得的控制点组的位置关系获取局部轨迹训练样本子集, 基于样本子集, 计算不完整轨迹样本的分类结果及概率, 最后, 基于动态时间规整方法对齐训练轨迹样本, 结合稀疏重构分析给出不完整轨迹测试样本的预测结果及预测轨迹模式。本文的主要研究内容和贡献如下:

- 1、在不完整目标轨迹表示和样本集获取的研究中, 采用基于 **LCSCA** (Least-squares Cubic Sparse Curves Approximation, 最小二乘三次 **B** 样条曲线逼近) 的轨迹表示算法, 用控制点描述轨迹, 解决了轨迹长度不一的问题。根据不完整轨迹与稀疏重构分析方法求得的控制点组的位置关系获取局部轨迹训练样本子集, 获得的局部样本子集与不完整测试轨迹运动形状最大程度相似, 用做行为模式学习的训练样本集合, 提高分类的准确率。

- 2、不完整轨迹分类及预测研究, 基于 **LCSCA** 轨迹样本描述, 采用 **SRA** (Sparse Reconstruction Analysis, 稀疏重构分析) 方法学习轨迹的行为模式, 并得

到相应行为类别概率，利用稀疏重构系数计算显示预测的行为轨迹，实现特定场景中的运动目标的行为预测。其中，稀疏重构分析方法不仅能得到不完整测试轨迹属于某种行为模式的概率，其稀疏重构系数还能反映出不完整测试轨迹与判定类别内训练样本的相似程度，使之能够用于计算预测的行为轨迹。

**关键词：**视频监控，目标轨迹表示，稀疏重构分析，不完整轨迹分类，不完整轨迹预测



## Abstract

Intelligent video surveillance is one important part in the field of computer vision research. Visual behavior analysis of moving object, abnormal behavior recognition and behavior prediction in intelligent video surveillance have a broad application prospects. Motion analysis is an important means of abnormal behavior detection and behavior prediction. The objects in surveillance scene move with some certain patterns rather than wander around. Information of these patterns can be used for the research of abnormal behavior detection and behavior prediction. Therefore, the subject of this thesis based on the patterns analysis has important theoretical significance and application value.

Since the sudden faults of tracking, blocking and some other reasons that a lot of incomplete tracks exist in the real surveillance scene. Based on the behavior analysis of moving object, the problem of incomplete trajectory prediction can be solved by learning the patterns of historical trajectories of surveillance scene, establishing a function mapping between the test trajectory and historical data. Using the mapping result, not only achieves the goal of predicting the future movement of the object, but also determines what pattern the object belongs to, and then detects the abnormality. Trajectory prediction can reduce security risks and make optimal route guidance. The issue has important research significance.

In this thesis, Based on the control points of cubic B-spline describe the trajectory, we using a local trajectories subset of complete trajectory calculate the classification and prediction probability of incomplete test sample. We obtain the local trajectories subset according to the positional relationship between the current position of test sample tracks and the control points which obtained by sparse reconstruction analysis. Finally, based on the Dynamic Time Warping (DTW) method of alignment training trajectories samples, we show the prediction result and pattern of the incomplete test trajectory. The main content and the contribution can be listed as following:

- 1) In the study of incomplete trajectory representation and the local subset of complete training trajectories establishing, we adopt the method named LCSCA (Least-squares Cubic Sparse Curves Approximation) to describe

trajectories with the control points, solving the problem of different length of motion trajectories. We get the local trajectories subset according to the positional relationship between the incomplete test sample and those control points. By this way, we can ensure the maximum similarity between the incomplete test sample and local trajectories subset which are used for behavior patterns learning.

- 2) In the study of incomplete trajectory classification and prediction, based on the LCSCA representation of trajectories, we proposed sparse reconstruction analysis (SRA) to learn the behavior pattern of each trajectory. By the reconstruction error minimum, we get the probability of each pattern. Furthermore, on the basis of DTW alignment training trajectories, we use the sparse reconstruction coefficient to calculate the predicted trajectory. With the SRA method we can not only get the probability of the incomplete test sample belonging to a certain pattern, but also the prediction trajectory by the sparse reconstruction coefficient which reflects the similarity between the incomplete test sample and the training data.

**Key Words:** Visual Surveillance, Motion Trajectory Representation, Sparse Reconstruction Analysis, Incomplete Trajectory Classification, Incomplete Trajectory Prediction

## 目录

摘要 .....	I
Abstract .....	III
目录 .....	V
图目录 .....	VII
表目录 .....	IX
第一章 绪论 .....	1
1.1 研究背景与意义 .....	1
1.2 国内外研究现状 .....	2
1.3 相关研究的发展趋势 .....	5
1.4 研究内容 .....	5
1.5 组织结构 .....	6
第二章 轨迹分类及预测相关技术综述 .....	9
2.1 运动目标轨迹表示 .....	9
2.2 行为模式学习 .....	13
2.3 基于目标行为模式学习的轨迹预测 .....	16
2.4 监控场景不完整轨迹分类及预测研究算法简介 .....	17
2.5 本章小结 .....	18
第三章 不完整轨迹表示及样本集构造 .....	19
3.1 研究框架 .....	19
3.2 基于 LCSCA 的目标轨迹表示 .....	20
3.2.1 最小二乘三次 B 样条近似 .....	21
3.2.2 基于 LCSCA 的目标轨迹表示 .....	25
3.3 局部轨迹样本子集获取 .....	27
3.4 实验结果及分析 .....	28
3.4.1 基于 LCSCA 的目标轨迹表示 .....	29
3.4.2 局部轨迹样本子集获取 .....	30
3.5 本章小结 .....	33
第四章 不完整轨迹分类及预测研究 .....	35
4.1 不完整轨迹分类 .....	35
4.1.1 稀疏重构分析 .....	36
4.1.2 基于稀疏重构分析的不完整轨迹分类 .....	38
4.2 不完整轨迹分类实验 .....	38
4.3 不完整轨迹预测 .....	42
4.3.1 基于 DTW 的不完整轨迹对齐 .....	42
4.3.2 基于稀疏重构分析的不完整轨迹预测 .....	43

4.3.3 不完整轨迹预测实验.....	45
4.4 本章小结 .....	48
第五章 总结与期望 .....	49
参考文献.....	51
作者简历及论文发表 .....	57
致    谢.....	59

## 图目录

图 1-1 基于模式学习的行为预测研究流程图.....	4
图 1-2 监控场景不完整轨迹的分类及预测研究框图.....	5
图 2-1 轨迹行为预测研究框架.....	16
图 3-1 不完整轨迹分类和预测研究框架.....	19
图 3-2 一般 B 样条曲线的保凸性示意图.....	23
图 3-3 一般 B 样条曲线的凸包性示意图.....	23
图 3-4 一般 B 样条曲线的变差缩减性.....	24
图 3-5 CAVIAR 场景数据集行为模式轨迹图.....	27
图 3-6 局部样本子集获取方法示意图.....	28
图 3-7 LCSCA 目标轨迹表示结果.....	29
图 3-8 不完整轨迹两种方法定义参数矢量的轨迹表示结果.....	30
图 3-9 局部轨迹样本子集获取结果.....	31
图 3-10 局部轨迹训练样本对不完整轨迹分类准确性的影响.....	32
图 3-11 局部轨迹样本获取结果.....	32
图 4-1 不完整轨迹分类和预测研究框架.....	35
图 4-2 基于稀疏重构分析的不完整轨迹分类.....	39
图 4-3 不完整轨迹长度为 80 帧时第 7 类和第 11 类的不完整轨迹训练集.....	40
图 4-4 不完整轨迹长度由 20 帧变化到 80 帧类别判断统计.....	40
图 4-5 不完整轨迹长度变化时分类统计及正确分类概率变化.....	41
图 4-6 不同控制点不同长度测试轨迹的正确分类的概率.....	41
图 4-7 DTW 累积距离矩阵和最短路径.....	43
图 4-8 DTW 对齐示意图.....	43
图 4-9 不完整轨迹预测模型.....	44
图 4-10 局部轨迹样本子集对轨迹预测的影响.....	45
图 4-11 不同长度的不完整轨迹预测实验结果.....	46
图 4-12 稀疏重构系数反映测试样本与训练样本的相似度.....	46
图 4-13 监控场景中障碍物对不完整轨迹预测的影响.....	47
图 4-14 基于 DTW 对齐轨迹和按最短轨迹直接截取得到轨迹预测结果.....	48



## 表目录

表 1 轨迹表示方法.....	10
-----------------	----





## 第一章 绪论

### 1.1 研究背景与意义

智能视频监控系统能够进行智能分析，直观、有效地处理视频数据，高效完成安全敏感的场合的安全保障任务，作为现实生活中一种有效的安防手段，在机场、银行、火车站、交通路口等场合发挥着重要的作用。智能视频监控能够实时采集场景数据，自动完成目标行为检测和行为分析，与传统监控系统相比节省劳力，在日益数字化、智能化的发展潮流中，被广泛的应用在军事、医学和科研等领域中。

作为计算机视觉领域中的主要研究方向之一，智能监控系统一般包括目标检测、目标跟踪、目标分类和异常行为分析四个研究问题，其中目标检测和目标跟踪是目标分类和异常行为分析的前提。目标跟踪时由于系统故障、场景中障碍物遮挡或者运动目标之间交互过多等原因，导致在视频图像序列中确定感兴趣的运动目标位置时，得到大量的不完整的动态图像系列。而智能监控系统的目的一般是通过对场景中的运动目标的行为做出解释，实现安全预警等作用。因此，对这些不完整的运动图像序列进行目标行为分析并预测其将来可能的运动行为，对于完成监控视频中目标分类和目标异常行为分析具有重要意义，是监控系统发挥安全预警作用不可或缺的部分。

现有的监控视频场景中目标重复性的进行某些行为，这种重复性的事件作为场景中运动目标行为分析研究的先验知识，被人们定义为场景中目标的典型运动模式，监控场景中的目标按照这些预先定义的行为模式运动，这样的研究方法过于依赖操作人员的主动性，对环境适应性不强。对监控场景中目标进行跟踪时，在视频图像序列中确定感兴趣的运动目标位置，将不同时刻同一目标的位置对应起来，可以得到反映出目标在该场景中的运动信息的三维时变序列（位置和时间信息）的轨迹数据。不同监控场景中大量的目标运动轨迹可以学习得到目标在相应场景中不同的运动行为模式。这样通过轨迹数据获得目标运动行为模式的方法比传统监控系统具有更好的适用性，在运动目标行为分析领

域具有重要的研究意义和发展潜力。

监控视频中运动目标的轨迹分析基于模式识别与人工智能等相关领域的成果，为运动目标的异常行为检测和行为预测提供了行之有效的方法。将轨迹预测理解成机器学习的问题，用历史轨迹数据学习运动模型（即行为模式），通过建立当前轨迹数据与历史观测数据之间的函数映射关系，不仅能预测目标将来运动行为，还能判断目标行为，进行异常行为检测，在很多监控场景中，轨迹预测能够减少安全隐患，并作最优路线指导，有着重要的研究意义。

不完整轨迹是指运动目标在监控场景中行进到当前时刻的短轨迹，这样的轨迹与完整轨迹在长度上相差较大。由于系统突然故障、场景中障碍物遮挡或者运动目标之间交互过多等的影响，监控系统通过跟踪获得的数据包含大量的不完整轨迹，对这些不完整轨迹进行目标行为分析并预测其将来可能的运动行为，对于完成监控视频中目标分类和目标异常行为分析，实现监控系统安全防范作用具有重要意义。如何对这些不完整轨迹进行行为识别及行为预测是运动目标行为分析领域的一个研究问题。基于不完整轨迹分析的行为模式学习和轨迹预测研究的关键问题是如何通过学习样本的轨迹数据，获取合适的分类模型将只有局部运动信息的不完整轨迹进行目标行为模式分类判断运动行为并做出轨迹预测。此外，作为目标行为分析的前提，目标检测和跟踪准确的结果影响目标行为分析准确性，对目标进行行为分析时，可以借鉴目标检测和跟踪领域的研究成果。

在研究工作期间，本文作者参与并受到以下课题的资助：

- 1) “基于多源数据的飞行器进近威胁目标检测跟踪及行为预测”，国家自然科学基金重点项目（课题编号：61039003）；
- 2) “飞行器威胁目标识别与图像鲁棒匹配理论与方法”，国家 973 计划子课题（课题编号：2010CB731804-2）。

## 1.2 国内外研究现状

智能监控系统能够从视频数据中自动学习得到场景的典型行为模式，实现

目标分类、异常检测、行为预测等目的，而不依赖于人为操作获取目标的运动信息，这样有效、智能的安防手段在民用、商业、国防安全和军事应用领域有着很大的需求，其巨大的应用前景使得各国研究人员投入了大量的人力物力进行研究。

国内外对基于运动目标轨迹分析的行为模式学习及预测的研究工作主要可以分为两部分，第一部分是运动目标轨迹学习的研究<sup>[1,2]</sup>，这部分工作的研究方法一般分为三个步骤<sup>[5-10]</sup>：(a) 监控场景中感兴趣的目标跟踪；(b) 就跟踪的目标提取特征序列（位置、形状等）；(c) 对这些特征序列表示的运动目标行为进行模式学习。第三个步骤是这部分研究工作的重点，即对从监控视频中获取的三维时变特征序列进行表示和分类，这样要解决的两个关键问题是：1) 轨迹的表示问题，即如何将时变的轨迹数据用另外的一个序列来表示，用于行为模式学习；2) 行为分析问题，即如何学习目标轨迹的行为模式分布来对目标的运动做出判断。

针对上述两个要解决的问题，国内外研究工作者经过多年的努力，取得了不错的研究成果，形成了一些经典的方法，按照不同的标准这些方法可以分为以下几种：

- 1) 轨迹表示可以分为归一化方法和降维的方法。归一化方法使所有轨迹长度一致，Hu 等<sup>[11]</sup>按照跟踪时间在轨迹的末端补零使轨迹长度一致，Morris 等<sup>[12]</sup>用重采样的方法，通过对原始轨迹线性内插使得轨迹长度相同。归一化的方法在完整轨迹上进行轨迹处理，操作简单、直观易懂，但对跟踪过程中存在大量的不完整轨迹适用性不强，而在环境复杂的监控场景中，除了目标分量（位置和时间信息）目标运动的形状和方向等信息更应该被考虑。轨迹降维将目标轨迹投影到另一个空间用合适的参数来表示轨迹，如向量量化<sup>[13]</sup>、曲线拟合<sup>[14]</sup>、核方法<sup>[15]</sup>等。综合考虑轨迹长度、运动方向和形状等信息，这些方法中曲线逼近因其对轨迹曲线灵活精准的表达得到很多研究工作者的青睐。Naftel 等<sup>[14]</sup>首次将函数逼近的方法用于轨迹表示，提出分别用最小二乘多项式、Chebyshev

多项式、DFT（离散傅里叶变换）三种方法计算系数特征向量来曲线表示轨迹。在 Naftel 研究工作基础上，Rowland 等<sup>[16]</sup>提出用 Haar 小波变换和三次 B 样条函数来求轨迹曲线的特征向量。

- 2) 基于目标轨迹的行为模式学习方法可以分为三类：有监督的学习方法、无监督的学习方法和半监督的学习方法。这三种方法的区别是用于学习的训练样本是否带有明确的标签。

获得运动目标的行为模式后，第二部分研究内容是对其运动轨迹进行预测。监控视频中基于行为分析的轨迹预测的一般研究方法是通过学习运动目标的轨迹模式，在轨迹模式学习基础上得到测试样本的行为模式类别概率，预测其最可能的运动行为。Bashir 等<sup>[17]</sup>将训练轨迹划分为片段轨迹，使用 K-means 聚类方法得到片段轨迹的行为模式类别，这些片段轨迹的行为模式类别作为隐马尔科夫的状态，利用状态之间的转移来预测其将来的行为；Piciarelli 等<sup>[18]</sup>使用树结构对轨迹建模，根据树节点之间的转移关系来判断目标将来的运动方向，达到预测目标行为的目的；Hu 等<sup>[19]</sup>用两层 FCM 聚类来进行模式学习，第二层的聚类结果用高斯分布建模，根据贝叶斯准则计算概率最大的运动方向。这些行为研究工作只能得到目标的运动方向或其预测的行进轨迹仅是训练样本的加和平均，不能反映目标轨迹与各个训练样本的相似程度。




图 1-1 基于模式学习的行为预测研究流程图

### 1.3 相关研究的发展趋势

通过以上介绍可以看出，基于目标轨迹的行为模式学习和行为预测受到广大研究人员的重视，并取得了一定的研究成果，尤其是基于目标轨迹的行为模式学习研究方面。但是，仍存在一些问题需要进一步研究改进，目标轨迹方面，轨迹长度不一、轨迹维度高影响行为模式学习模型的准确性；行为模式学习方面，场景中障碍遮挡或运动目标之间相互遮挡使得到的视频数据存在大量的不完整轨迹，这些不完整轨迹普遍长度较短，运动信息不完整，这使得在对不完整轨迹进行分类时不能分类或分类的准确率较低；此外，监控场景的多样性也会导致分类模型建立的计算复杂度大并且对轻微的运动特征变化不够鲁棒，如何提高不完整轨迹行为模式学习模型的准确性和鲁棒性是目标行为分析的一个重要研究重点。行为预测方面，当前的研究工作大多在得到目标轨迹的行为模式类别后按概率关系预测目标的运动方向或者得到加和平均的预测轨迹，如何利用目标轨迹与训练样本之间的相似关系来计算更合理准确的预测轨迹。基于研究中存在的这些问题，未来的研究工作重点在获取更有效的轨迹表示、提高分类模型的鲁棒性以适应复杂多变的目标行为、得到更合理的行为预测的方法。

### 1.4 研究内容




图 1-2 监控场景不完整轨迹的分类及预测研究框图

当前基于行为分析的轨迹预测研究一般是通过学习运动目标的轨迹模式，在轨迹模式学习基础上得到测试样本的行为模式类别概率，这样的预测工作通常只能预测目标的运动方向，不能得到将来长时间内目标的轨迹的预测。为使轨迹表示包含目标运动方向信息、解决轨迹长短不一、运动形状多变的问题；此外，为提高不完整轨迹的行为模式学习准确率，使目标行为预测时除了预测目标的运动方向，还能依据已有的场景样本的轨迹信息计算将来较长时间内的预测轨迹。基于以上目的，本文以三次 B 样条控制点拟合做轨迹表示，引入稀疏重构分析理论，提出根据不完整轨迹与稀疏重构分析方法求得的控制点组的位置关系获取局部轨迹训练样本子集；基于稀疏重构分析方法对不完整轨迹进行分类，得到不完整轨迹测试样本的行为模式类别及概率后，使用动态时间规整算法对齐训练轨迹样本，利用反映不完整测试轨迹与类别间训练样本的相似程度的稀疏重构系数计算不完整测试样本的预测轨迹。在目标轨迹长度相差较大、运动方向多变的情况下，该方法能有效提高不完整轨迹的分类准确度，不仅能预测不完整轨迹的行为模式类别，还能获得较为准确的预测轨迹。针对前面提到运动目标轨迹行为模式学习和行为预测存在的问题，本文研究重点为提高不完整轨迹的分类准确率以及获取合理的预测轨迹，本文的研究框架如图 1-2 所示。

## 1.5 组织结构

第一章，绪论。主要论述了基于运动目标轨迹分析的目标轨迹表示、行为模式学习及行为预测的研究背景和意义，分析了国内外在这三个领域的研究现状和发展趋势，列出本文的主要研究目的和研究内容。

第二章，基于运动目标轨迹分析的行为模式学习及预测的研究基础。介绍目标轨迹表示、行为模式学习和行为预测的主要研究内容和已有的研究方法，同时对本文研究所采用的轨迹表示方法和不完整轨迹学习分类的方法进行简单的介绍。

第三章，基于 LCSCA 的不完整轨迹表示和样本集构造。介绍最小二乘三系

B 样条的目标轨迹表示方法，详细介绍轨迹数据三次 B 样条曲线上控制点位置关系获取不完整轨迹分类所需的局部轨迹样本子集作为分类及预测研究的训练样本集，通过实验 LCSCA 轨迹表示方法在目标轨迹长度不一、运动方向多变等情况下的鲁棒性，并通过对比实验对局部样本子集提高分类准确率的有效性进行验证。

第四章，基于稀疏重构分析的不完整轨迹分类及预测。介绍稀疏重构分析方法，论述其稀疏优势及其求解方法，在此基础上，应用稀疏重构分析方法对不完整目标轨迹进行分类和预测。依据稀疏重构分析方法获取不完整轨迹的重误差实现目标轨迹行为模式类别判断，获得稀疏重构系数以及目标轨迹行为模式类别预测概率，动态时间规整算法对齐训练样本轨迹，利用稀疏重构系数计算不完整轨迹的预测轨迹，给出分类及预测实结果，验证分析算法的有效性。

第五章，总结与期望。总结本文的主要研究工作，就研究工作已取得的成果和存在的问题进行分析，并对如何进一步提高长度较短的不完整轨迹分类算法的鲁棒性、准确性以及如何对运动目标预测轨迹的准确性作合理评价等问题进行探讨。





## 第二章 轨迹分类及预测相关技术综述

监控视频中运动目标行为模式学习是计算机视觉领域的一个热点研究问题，提高行为模式学习的准确性和鲁棒性并对目标行为进行预测逐步成为监控视频运动目标行为分析的研究重点。本章将主要介绍基于目标行为模式学习的行为预测研究中目标轨迹表示、行为模式学习及预测三部分研究内容和已有的方法，并对本文所采用的轨迹表示方法以及基于稀疏重构分析的不完整轨迹分类和行为预测的研究框架做简单介绍。

一个智能的监控系统能够观察场景中目标的运动信息，利用这些信息，自动对目标运动行为模式进行判断，并预测其将来的行为。运动目标轨迹记录目标在监控场景中运动行为从开始到结束的位置和时间信息，对监控场景中运动目标行为分析可以利用轨迹包含的这些运动信息对目标行为建模。监控场景环境复杂、运动目标交互过多等原因使得监控场景中目标运动行为模式种类很多，无法直接用一种模型训练得到目标的行为模式，需要在训练前对获取场景中目标的运动数据作处理。针对这种情况，本文把监控场景中不完整轨迹分类和预测分为两步，首先是运动目标轨迹表示，把三维时变序列的轨迹数据变化为表示序列，构建训练样本集；第二步是对不完整轨迹进行分类和预测，分类是将不完整测试轨迹与预先标定的代表场景中典型行为模式的局部样本轨迹进行匹配，匹配过程获得的参数用来判断目标轨迹行为模式类别并计算目标将来时刻的预测轨迹。

### 2.1 运动目标轨迹表示

监控系统运动目标行为分析研究近二十年来得到充分的发展，相关的算法越来越多，运动目标轨迹是现存很多监控视频目标行为建模、聚类、分类算法的基础。监控场景运动目标行为分析按照轨迹预处理方法不同可以分为两类：基于归一化的目标轨迹表示方法和基于降维的目标轨迹表示方法，对目前研究中这两类方法的总结见表 1。

表 1 轨迹表示方法

归一化	降维
1) 补零法 <sup>[11]</sup> 2) 轨迹延长法 <sup>[21]</sup> 3) 重采样法 <sup>[22-25]</sup> 4) 滤波法 <sup>[18,24,26]</sup>	1) 向量量化 <sup>[27,28]</sup> 2) 曲线拟合 <sup>[16,17,29]</sup> 3) 多分辨率分解 <sup>[14,15,30,31]</sup> 4) HMM <sup>[32]</sup> 5) 子空间方法 <sup>[17,33]</sup>
在完整轨迹上操作，对不完整 轨迹不适用，确保轨迹长度一 致	将轨迹映射到另一个参数空 间，用合适的参数表示轨迹

◆ 基于归一化的目标轨迹表示方法：

这一类方法在完整轨迹上操作，处理后一般直接将目标轨迹的分量（位置、速度、加速度等信息）作为表示序列。Hu<sup>[19]</sup>采用补零法在运动到 $T$ 时刻的轨迹末端补零延长目标轨迹至 $T'$ 时刻， $T'$ 的长度选训练样本集中最长的长度，这种方法虽然能得到长度一致的轨迹，但会让轨迹空间很大且当 $T'$ 为异常值（目标跟踪的时间很长）时受到很大的限制。重采样通过对原始轨迹内插的方法保证轨迹长度一致，线性内插和二次采样时两种比较常见的方法<sup>[20,34,35]</sup>。滤波放用一些简单的滤波器<sup>[17,24]</sup>或小波<sup>[25]</sup>等信号分解器滤除轨迹的噪声，滤波完的轨迹再用内插或采样的方法来获得固定长度的表示序列。

基于归一化的目标轨迹表示方法计算简单、直观易懂、在完整轨迹长操作，但是在跟踪过程中由于多种原因存在大量不完整轨迹，归一化的方法这些不完整轨迹不适用。

◆ 基于降维的轨迹表示方法：

复杂的监控场景中存在大量不完整轨迹，对目标轨迹的行为分析除了考虑轨迹数据的位置和速度等信息，应该更多关注目标轨迹的运动形状、方向等信息。针对这些情况，为了获取更鲁棒的目标轨迹的行为模式学习，近年来轨迹表示的研究产生轨迹降维的方法。轨迹降维是将目标轨迹映射到更容易计算的参数空间，用一组参数来描述轨迹模型。向量量化降维是用数量有限的典型向量来

特征表示场景中所有的轨迹<sup>[36-38]</sup>。基于曲线逼近的目标轨迹表示方法实质是将轨迹数据通过某种变换求得表示矩阵的方法，即将  $\{\bar{X}, \bar{Y}, \bar{T}\}$  表示为  $[C_1^X, \dots, C_M^X, C_1^Y, \dots, C_M^Y]$ 。Naftel 等<sup>[14]</sup>首次用曲线逼近的方法表示目标轨迹，其分别用最小二乘多项式、Chebyshev 多项式、离散傅里叶变换(Discrete Fourier Transform, DFT)三种方法计算轨迹曲线的特征矢量，在参数空间中用这些特征来表示轨迹。Rowland 等<sup>[16]</sup>Naftel 研究工作基础上,使用 Haar 小波变换、DFT、Chebyshev 多项式函数逼近轨迹曲线的系数特征矢量来表示轨迹，并将这三种方法与三次 B 样条控制点特征矢量表示轨迹的方法作对比，通过不同数据集上的实验结果发现三次 B 样性能较好。在以下是三种典型曲线逼近目标轨迹的求解方法介绍：

- 1) Chebyshev 多项式系数法。切比雪夫多项式是定义在[-1,1]对偶区间一系列正交化多项式，其在曲线逼近上的应用是因为第一类切比雪夫多项式的根可用于多项式插值，能够提供多项式在连续函数的最佳一致逼近。在[-1,1]区间上定义第  $n$  个切比雪夫多项式如公式 (2-1) 所示，用  $m$  阶切比雪夫多项式曲线逼近表示  $Q_n(t)$ ，得到公式 (2-2)，其中是需要求解的用于描述轨迹的切比雪夫多项式参数，由于切比雪夫是定义在对偶区间上的正交化多项式，所以计算  $b_n$  时需要把定义域变换到对偶的区间上，所以该算法有一定的局限性。

$$Q_n(t) = \cos(n \cos^{-1}(t)) \quad (2-1)$$

$$x(t) = \sum_{n=0}^m b_n Q_n(t) \quad (2-2)$$

- 2) 离散傅里叶变换法。离散傅里叶变换将轨迹数据变成其他空间上的另一堆数据，如公式 (2-3) 所示，其中  $\bar{X} = [x_1, \dots, x_N]$  为轨迹坐标数据， $N$  为  $\bar{X}$  的长度， $j$  为虚数单位  $j = \sqrt{-1}$ ，最后用傅里叶变换结果中的实部和虚部来做轨迹表示的参数，即公式 (2-4)，其中  $\Re(z)$  是  $z$  的实部， $\Im(z)$

是  $z$  的虚部,  $\Im(f_1(\bar{X}))$  等于 0。

$$f_k(\bar{X}) = \frac{1}{N} \sum_{n=1}^N x_n \exp\left(-\frac{2\pi j(k-1)(n-1)}{N}\right) \quad (2-3)$$

$$\bar{C} = \left[ \Re(f_1(\bar{X})), \Re(f_2(\bar{X})), \Im(f_2(\bar{X})), \dots, \Re(f_M(\bar{X})), \Im(f_M(\bar{X})) \right] \quad (2-4)$$

- 3) Haar 小波系数法。该方法在 Haar 小波变换的尺度函数和小波函数, 通过求小波系数来表示轨迹数据。Haar 小波变换的尺度函数  $\phi(s)$  和小波函数  $\psi_{j,k}(s)$  定义见公式 (2-5) 及 (2-6), 其中  $k \in [0..2^j-1]$  和  $j$  分别为位置和尺度参数。算法要求轨迹长度为 2 的整次幂, 用公式 (2-7) 的两个解析表达式用来计算 Haar 小波系数, 公式中  $\bar{X} = [x_1, \dots, x_N]$  为轨迹数据,  $N$  为轨迹长度, 用得到的小波系数表示目标轨迹, 见公式 (2-8)。

$$\phi(s) = \begin{cases} 1 & \text{if } 0 \leq s < 1 \\ 0 & \text{otherwise} \end{cases} \quad (2-5)$$

$$\psi_{j,k}(s) = 2^{\frac{j}{2}} \psi(2^j s - k), \quad \psi(s) = \begin{cases} 1 & \text{if } 0 \leq s \leq \frac{1}{2} \\ -1 & \text{if } \frac{1}{2} < s \leq 1 \\ 0 & \text{otherwise} \end{cases} \quad (2-6)$$

$$\alpha = \frac{1}{N} \sum_{i=1}^n \phi(s_i) \cdot x_i, \quad \beta_{j,k} = \frac{1}{N} \sum_{i=1}^n \psi_{j,k}(s_i) \cdot x_i \quad (2-7)$$

$$\bar{C} = \left[ \alpha, \beta_{0,0}, \dots, \beta_{J-1, 2^J-1} \right] \quad (2-8)$$

曲线逼近的轨迹表示方法得到的轨迹表示序列包含了目标的形状、方向等信息, 相比轨迹数据的分量, 更多地关注轨迹曲线的趋势信息, 对监控场景中由于遮挡等原因造成跟踪得到的不完整轨迹的分类和行为预测具有鲁棒性; 再者, 曲线逼近的方法表示轨迹可以得到长度一致的表示序列, 可以很容易地与很多行为模式分析的方法结合使用, 基于以上优点, 曲线逼近的轨迹表示在众

多的轨迹表示方法受到研究人员青睐。本文采用的基于最小二乘三次 B 样条的目标轨迹表示属于曲线逼近的目标轨迹表示。

## 2.2 行为模式学习

监控场景运动目标行为模式学习经过这些年的发展，研究人员的工作越来越集中于模式学习算法的鲁棒性上。运动目标行为模式学习的算法各式各样，总结主要可以分为三类：有监督的学习方法、无监督的学习方法和半监督的学习方法。

### ◆ 有监督的学习方法：

有监督的行为模式学习方法是指在预先定义场景中所有行为模式类别情况下，训练样本的类标签已知，通过对样本集合的训练和学习得到描述这些训练样本行为模式的模型。对监控场景中运动目标行为分析时利用训练学习得到的模型，可以对新样本进行学习得到新样本的行为模式类别。有监督学习得到行为模式模型容易在其他数据集上得不到期望的效果，因为训练模型容易出现“过拟合”和“欠拟合”。这类方法一般包含以下几种经典的算法：

- 1) HMM (Hidden Markov Model, 隐马尔科夫模型)。作为生成模型的一种，HMM 的状态不能直接观察到，但可根据隐藏状态与观测向量序列之间的概率关系观察得到，每一个观测向量是由一个具有相应概率密度分布的状态序列产生<sup>[39,40]</sup>。近年来，HMM 成功的被应用于监控场景中的行为识别，很多在 HMM 基础上的改进算法被提出来。Oliver 等<sup>[41]</sup>提出并比较了 HMM 和 CHMM (Coupled Hidden Markov Models) 两种方法对场景中人的行为建模；Duong 等<sup>[42]</sup>在 HMM 基础上提出用转换隐马尔科夫模型 (Switching Hidden Markov Models) 对人们的行为进行学习实现异常行为检测的目的。Dizan 等<sup>[43]</sup>提出增长隐马尔科夫模型 (Growing Hidden Markov Model) 的增量学习重采样算法对运动目标轨迹矢量进行学习，该方法对每一个新的观测状态序列，都更新离散状态数目、状态矩阵和概率参数。

- 2) **SVM (Support Vector Machine)**。SVM 是基于统计学习理论和最小化结构风险原理基础上的分类、回归技术，成功地被应用于处理回归和模式识别等诸多问题中。SVM 最早被 Vapnik 等<sup>[44]</sup>提出，后来 Boser 等<sup>[45]</sup>结合核方法将 SVM 延伸用于处理非线性问题。Scholkopf 等<sup>[46]</sup>在 SVM 的基础上提出 One-Class SVM 算法。One-Class SVM 的基本思想是将低维不可分的样本映射到高维特征空间中，在特征空间中构建描述样本分布的概率函数，建立样本数据分布的二值模型，依据建立的模型，将测试样本在特征空间的像与原点以最大间隔分开，判断测试样本是否属于该类。Piciarelli 等<sup>[47]</sup>用固定长度的向量来表示重采样的目标轨迹，再使用 One-class SVM 方法来获取分类模型，并用得到的分类模型对场景中的运动目标进行异常行为检测。
- 3) **FSM (Finite State Machine, 有限状态机)**。FSM 是一种有有限个状态并且这些状态之间能够互相转换的数学模型，它能够存储场景中过去时刻目标的运动信息并更新已经检测到和最新检测到的目标之间、同一目标在不同时刻之间的关系。FSM 有限个状态之间相互转移得到的状态转移函数用来确定最佳状态，并用该状态确定测试样本和参考样本是否匹配<sup>[20]</sup>。刘<sup>[47]</sup>在轨迹分析中利用 FSM 将交通驾驶环境区域定义为不同的状态，根据不同状态之间的转移确定不同的行为，以检测在交通驾驶中的危险事件。

◆ 无监督的学习方法：

相对于有监督的学习方法，无监督学习的训练样本不带标记，直接对这些训练样本进行学习，找到训练数据反映场景中运动目标的行为模式的隐藏结构。无监督学习的典型方法有轨迹聚类分析方法和自组织神经网络学习。

轨迹聚类分析方法将场景中的相似的训练轨迹分为一类，轨迹之间相似性度量的定义很重要，不同的相似性度量方法，目标轨迹聚类效果也不一样。目标轨迹可以用二维或三维的坐标序列来表示， $\{(a_1^x, a_1^y), (a_2^x, a_2^y), \dots, (a_n^x, a_n^y)\}$  为目

标轨迹在二维空间下表示的坐标序列。常用作轨迹相似性度量的几种典型的距离度量有：Euclidean 距离、PCA（Principle Components Analysis, 主成分分析）+Euclidean 距离、Hausdorff 距离、LCSS（Longest Common Subsequence, 最长公共子序列）距离、DTW（Dynamic Time Warping, 动态时间规整）距离。

对轨迹相似性度量定义之后，很多轨迹聚类的方法相继提出,这些方法将相似的轨迹分成一类，最后得到场景中不同行为模式。K-means 是其中一种非常经典的无监督轨迹聚类方法。该算法随机选取  $K$  个聚类质心，通过没有类别标签的无标记训练样本计算离其最近的质心，将其分为相应的类，最后在所有训练样本分类完毕后重新计算每一类的质心，重复后两个步骤直到收敛。K-means 算法操作简单，在广泛应用于监控场景运动目标行为分析领域对未标记的轨迹数据聚类学习。Stauffer 和 Crimson Deng 等<sup>[48]</sup>将轨迹量化成一个码本来描述运动目标的位置和速度，再用在线 K-means 聚类方法构造该码本的联合共生统计量表对训练轨迹进行分类。在 K-means 基础上，针对场景中目标的复杂运动行为，Bezdek 等<sup>[49]</sup>用 FCM（Fuzzy C-means, 模糊 C 均值）聚类方法学习目标行为模式，K-means 中每条轨迹只能属于一个类，而在模糊 C 均值算法中，每条轨迹可以属于两个或多个类。Hu 等<sup>[19]</sup>用两层 FCM 算法聚类学习目标行为模式。Liu 等<sup>[37]</sup>提出基于马氏距离的 FCM 算法对场景中轨迹聚类分析。

SOM 神经网络是一种无导师的聚类方法，由输入层和输出层构成，输入层是一维的神经元，神经节点数为输入数据的维数，输出层是二维的节点矩阵，输入层与输出层有相应的权值实现全连接。SOM 的算法思想是，输入层某类数据输入时，输出层的某个节点得到最大刺激而获胜，获胜节点周围的一些节点也因侧向作用受到较大的刺激<sup>[50]</sup>，此时网络进行一次学习，对获胜节点及其周围受到较大刺激的节点与输入数据节点相连接的权值进行修正，当输入数据类型发生变化时，输出层的获胜节点也会发生变化，由原来的节点转移到二维平面上的其他节点。通过对输入层输入数据模式的反复学习，最后得到输出层二维节点矩阵能够反映输入数据的分布情况，判断输入数据的模式类别。Johnson 等<sup>[51]</sup>训练过程中对目标轨迹线性重采样得到一致的点密度，用流失量表示轨迹

的空间位置和运动信息作为 SOM 神经网络的输入，通过 SOM 神经网络来学习流失量的分布。

◆ 半监督的学习方法：

在很多时间监控场景中，获得的场景数据只有少量带有标记，很多都没有类标签，基于这样的实际情况，同时利用带有标记的数据和没有标记的数据的半监督学习技术受到研究人员的重视，并且迅速发展了起来。

K 最近邻 (K-Nearest Neighbor, KNN) 算法有着成熟的理论基础，算法简单、直观、易实现，在机器学习、模式识别领域得到广泛的研究，是一种常用的模式学习方法。该方法的基本思想是训练样本集中，查询未知样本最相似的  $K$  个近邻点，近邻点最多的类别即为该样本点所属。具体思路是以某种相似度为度量，寻找离样本点最近的  $K$  个近邻样本点，并把测试样本  $x$  的标号设为这  $K$  个近邻样本中出现次数最多的类别。其中测试样本与训练样本的相似度一般包含有欧式距离、曼哈顿距离、切比雪夫距离、闵可夫斯基距离、马氏距离等。

GMM (Mixture Guassian Model, 混合高斯模型) 半监督学习方法<sup>[52]</sup>，当训练样本变化时，逐次更新 GMM 的部分权重、均值以及方差直到结束，最后得到行为模式分类模型。

### 2.3 基于目标行为模式学习的轨迹预测

监控场景行为分析研究通过对场景历史轨迹数据处理，学习场景的行为模式，依据学习得到的行为模式，判断测试轨迹的行为模式类别，并计算其属于某中行为模式的概率，预测将来的行为，这样用机器学习的方法对观测得到的历史轨迹数据建立的分类模型,不仅能得到目标最可能的运动方向预测，还能预测目标轨迹将来行进的具体位置及概率分布。当前的轨迹预测研究主要是基于这样一种对场景历史数据行为模式学习的预测，如图 2-1 所示。




图 2-1 轨迹行为预测研究框架



Dizan 等<sup>[43]</sup>对场景训练轨迹用聚类的方法得到场景的运动行为模式，计算测试轨迹数据与每一类行为模式的似然函数，选取似然值最大的行为模式为测试轨迹将来的运动行为。Ellis 等<sup>[53]</sup>提出一种非参数的长轨迹预测研究框架，该研究中用高斯过程对训练轨迹建立一个概率模型，用得到的概率模型估计目标下一时刻的运动位置，如此递归计算实现长轨迹的预测。Hermes 等<sup>[54]</sup>提出四元旋转不变最长公共子序列方法作为轨迹间相似性度量，使用粒子滤波算法跟踪运动目标获取轨迹数据，在跟踪数据内计算概率密度函数预测目标位置。Keller 等<sup>[55]</sup>应用 Hermes 等<sup>[55]</sup>研究框架对行人行为（行走、停止）分类，粒子滤波权值最大的行为模式为目标预测的行为。Hermes 等<sup>[55]</sup>在 2011 年使用历史轨迹数据获取场景的行为模式来预测运动目标行为，具体做法先用 Chebyshev 多项式表示目标轨迹，将轨迹数据映射到一个参数空间中，利用 UKR（Unsupervised Kernel Regression，无监督和回归）方法将参数向量投射到低维的流形场中，在该流形场中用粒子滤波跟踪历史轨迹数据并预测运动目标的位置。Bashir 等<sup>[17]</sup>将训练轨迹划分为片段轨迹，使用 K-means 聚类方法得到片段轨迹的行为模式类别，这些片段轨迹的行为模式类别作为隐马尔科夫的状态，利用状态之间的转移来预测其将来的行为；Piciarelli 等<sup>[47]</sup>利用树结构来表示轨迹，根据树节点之间的转移关系来预测目标的行为；Hu 等<sup>[19]</sup>用两层 FCM 聚类来进行模式学习，第二层的聚类结果用高斯分布建模，根据贝叶斯准则计算概率最大的运动方向。

## 2.4 监控场景不完整轨迹分类及预测研究算法简介

监控场景基于运动目标轨迹模式学习的行为预测算法研究的两个重心点是行为模式学习的鲁棒性和轨迹预测的准确性。行为模式学习方面，监控场景环境多变、跟踪中断、遮挡、运动目标交互等因素造成得到大量不完整轨迹，轨迹数据长度不一、运动轨迹形状多变等问题往往影响行为模式学习的准确性，为减少这些影响，在对轨迹进行行为模式学习前需要对轨迹数据进行预处理，将轨迹用另外的表示序列进行描述。近年来，轨迹表示研究算法中，基于曲线逼近的轨迹表示方法因其较好的描述效果，受到越来越多的关注。轨迹模式学

习的方法越来越集中于方法的鲁棒性上，前文总结中轨迹模式学习方法可以分为有监督学习、无监督学习和半监督学习三类方法。轨迹预测方面，目前的研究工作大多是得到运动目标属于某种行为模式的概率，预测其将来的运动方向或者将来很短时间内的运动位置，并不能得到未来长时间内的轨迹预测结果。

本文对监控场景中的不完整轨迹分类并预测其将来的行为，采用 LCSCA 目标轨迹表示方法，该算法可以简单总结为：根据目标轨迹分布趋势，将轨迹数据  $T = \{(x_1, y_1), (x_2, y_2), \dots, (x_{N-1}, y_{N-1}), (x_N, y_N)\}$ ，通过非均匀三次 B 样条基函数变换，求得参数序列  $F = \{C_1^x, C_2^x, \dots, C_p^x; C_1^y, C_2^y, \dots, C_p^y\}$ ，用该序列表示目标轨迹，其中  $p$  为控制顶点个数，该方法中的控制顶点和权值因子能够灵活的描述和解析各种形状的轨迹曲线<sup>[56]</sup>。用 LCSCA 方法表示轨迹后，提出基于稀疏重构分析的轨迹分类预测算法，将不完整测试轨迹用代表场景中典型行为的训练样本来稀疏表达，根据重构误差判断测试样本的行为模式类别并计算测试样本属于某种行为模式的概率，重构系数反映不完整测试轨迹与代表某种行为模式的训练样本的相似程度，利用重构系数可以获得较为准确且合理的不完整测试轨迹行为结束前的预测轨迹。

## 2.5 本章小结

本章对轨迹表示、行为模式学习、基于行为模式学习的轨迹预测这三部分的主要研究内容、研究方法进行了综述。首先介绍了归一化和降维两大轨迹表示方法，并对降维中的曲线逼近方法详细介绍；接着介绍了三种行为模式学习方法和轨迹预测的算法；最后，简单介绍了本文研究内容及所采用的方法。

### 第三章 不完整轨迹表示及样本集构造

当前基于对目标轨迹行为模式的学习越来越集中于提高模型的鲁棒性，轨迹长度不一、运动行为复杂、样本数目少等都是这一领域研究重点研究问题。不完整轨迹指场景中运动目标行进到当前时刻的短轨迹，对不完整轨迹的行为识别和预测可以有效完善监控系统安全预警的功能。本文对不完整轨迹分类和预测研究提出用 LCSCA 算法表示目标轨迹，按照不完整轨迹当前时刻位置与描述训练样本轨迹三次 B 样条函数控制点位置关系获取局部轨迹子集作为不完整测试轨迹的分类和预测研究的训练样本，图 3-1 中蓝色为本章的主要介绍内容。

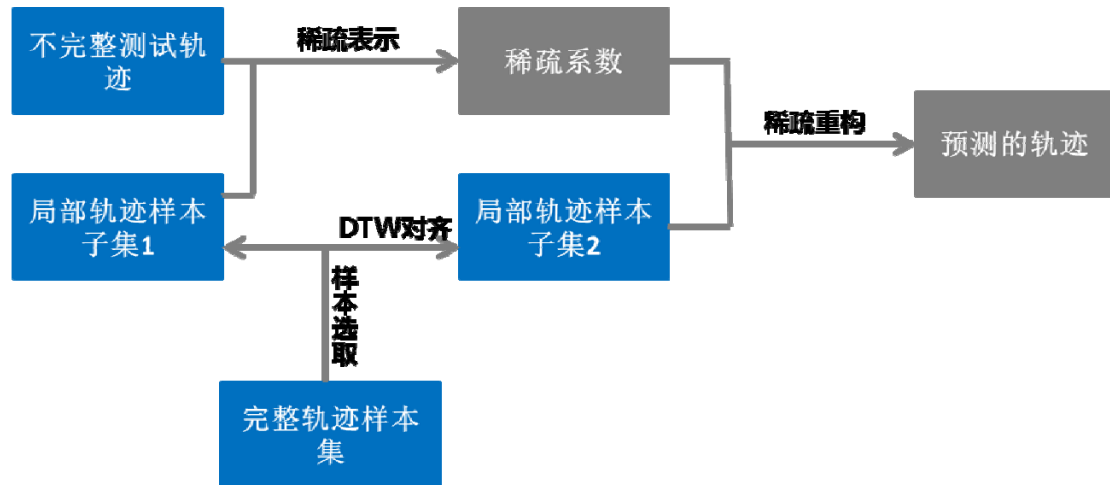


图 3-1 不完整轨迹分类和预测研究框架

#### 3.1 研究框架

**基于 LCSCA 的轨迹表示和样本集构造：**最小二乘三次 B 样条对目标轨迹的三维时变序列数据进行变换求解，用一个固定长度的参数向量来描述任意长度的轨迹，使之包含运动轨迹的形状和时空信息，其控制顶点和权值因子能够灵活且精准地描述各种形状的轨迹曲线。本文的研究中，采用该方法表示目标轨迹，具体做法：根据运动目标轨迹长短和其分布趋势，构造参数矢量和非均匀节点矢量，用得到的非均匀节点矢量构造 B 样条基函数，定义反求控制点的系数矩阵，建立反算方程，用轨迹的数据点为型值点反求出用以描述轨迹的控制点<sup>[20]</sup>。最后，根据不完整轨迹当前位置点与训练样本的控制点组中心位置距

离关系获取用以不完整轨迹分类和预测的局部样本子集作为不完整轨迹分类及预测研究的训练样本集合。这样通过定义控制点用 B 样条曲线对不同长度的轨迹获得固定长度的参数向量表示，解决了轨迹长度不一的问题。控制点集中表现目标轨迹运动的变化，包含目标的运动方向信息，根据训练样本控制点组中心位置关系获取局部样本子集，保证这些局部轨迹样本在运动形状变化与不完整测试轨迹的相似度，为提高后面不完整轨迹分类的准确性奠定基础，研究中给出实验分析结果验证了研究采用的轨迹表示方法的有效性。

**基于稀疏重构分析的不完整轨迹分类及预测：**基于目标轨迹行为模式学习的行为预测可以分为不完整测试轨迹分类和预测两个过程。监控场景复杂多变的环境使得场景中的行为模式很多，用样本集进行测试样本进行重构时，会导致系数稀疏，很多行为模式类别的样本对应的重构系数趋近于零，而稀疏重构分析方法可以使运动信息集中在少数系数非零的样本上。在轨迹表示部分获得局部样本子集基础上，用稀疏重构分析方法将不完整轨迹与预先标定的能代表场景中典型行为的训练样本进行匹配分类，获取局部样本子集中样本对应的重构系数和重构误差，对这些重构系数和重构误差进行评估，重构误差最小的样本用来重构不完整测试轨迹的概率最大，该部分样本对应的重构系数反映不完整测试轨迹与这些样本的相似程度。通过每一种行为模式类别样本重构误差评估获得不完整轨迹运动方向的预测，使用动态时间规整算法对齐训练样本，使样本长度一致，根据重构系数计算测试样本的预测轨迹。该方法能够对监控场景中较短的不完整轨迹进行行为检测，具有较强的鲁棒性，对不完整轨迹的行为预测除了预测其运动方向还能获取合理的预测轨迹。本文通过实验结果对算法的有效性进行验证。

### 3.2 基于 LCSCA 的目标轨迹表示

对不完整轨迹在行为模式学习基础上进行轨迹预测研究，由于训练轨迹长度不一、不完整轨迹长度较短、运动信息不完整等因素影响，影响不完整轨迹分类。因此，在对不完整轨迹分类预测前需要先对轨迹进行预处理。研究过程

在采用基于 LCSCA 的轨迹表示, 三次 B 样条控制点能够灵活描述各种形状的轨迹曲线, 在获得轨迹固定长度表示的同时, 得到的轨迹表示序列包含目标的运动方向信息。

### 3.2.1 最小二乘三次 B 样条近似

1964 年, 美国数学家 I.J.Schoenberg 第一次提出样条函数的概念, 作为贝兹曲线的一般化, 这位数学家定义了一种 B 样条函数<sup>[57][58]</sup>, 非均匀有理 B 样条是在 B 样条函数基础上推广延伸得到。LCSCA 是在非均匀有理三次 B 样条理论上结合函数逼近理论产生, 它能有效克服贝兹曲线不能局部修改的缺点, 权值因子和控制顶点还能灵活表示形状多变的轨迹。正因为 LCSCA 优异的几何特性, Rowland 等<sup>[16]</sup>将三次 B 样条与函数逼近的理论结合用于表示目标轨迹, Li<sup>[20]</sup>2012 年采用 LCSCA 算法表示监控场景目标轨迹, 将轨迹数据转换成相应的参数向量表示后用于场景中运动目标的行为模式学习, 文献显示的实验结果中, 这种轨迹表示方法得到了较好的异常行为检测结果。

**B 样条基函数:** B 样条基函数是一个由单调递增参数矢量  $t$  决定的  $k$  阶多项式,  $t$  也被称为节点矢量, 公式 (3-1) 为  $k$  阶 B 样条曲线的定义, 其中  $P_0, P_1, \dots, P_n$  为曲线的控制顶点,  $N_{i,k}(t)$  是  $k$  次 B 样条曲线的基函数。B 样条定义使用 De Boor-Cox 递推可以得到公式 (3-2) 的  $k+1$  阶的 B 样条基函数定义, 约定:  $\frac{0}{0} = 0$ 。

$[t_i, t_{i+k}]$  为第  $i$  个  $k$  阶 B 样条  $N_{i,k}(t)$  的支撑区间。

$$P(t) = \sum_{i=0}^n P_i N_{i,k}(t) \quad t_{k-1} \leq t \leq t_{n+1} \quad (3-1)$$

$$N_{i,0}(t) = \begin{cases} 1 & \text{if } t_i \leq t \leq t_{i+1} \\ 0 & \text{otherwise} \end{cases} \quad (3-2)$$

$$N_{i,k}(t) = \frac{t-t_i}{t_{i+k-1}-t_i} N_{i,k-1}(t) + \frac{t_{i+k}-t}{t_{i+k+1}-t_{i+1}} N_{i+1,k-1}(t)$$

在实际研究应用中多采用 De Boor-Cox 递推定义的 B 样条基函数, 它具有以下性质:

- 1) 局部支撑性和非负性: 
$$\begin{aligned} N_{i,k}(t) &\geq 0, & t \in [t_i, t_{i+k}] \\ N_{i,k}(t) &= 0, & t \notin [t_i, t_{i+k}] \end{aligned}$$
- 2) 权性: 对于相同的  $k$ , 对任一  $t \in [t_{k-1}, t_{n+1}]$ , 有: 
$$\sum_{i=0}^n N_{i,k}(t) = 1。$$
- 3) 除  $k=0$  外,  $N_{i,k}(t)$  存在唯一极大值, 除  $k=1$  和  $k=2$  外,  $N_{i,k}(t)$  均为连续平滑曲线。
- 4)  $N_{i,k}(t)$  微分公式: 
$$N'_{i,k}(t) = \frac{k-1}{t_{i+k-1}-t_i} N_{i,k-1}(t) - \frac{k-1}{t_{i+k}-t_{i+1}} N_{i+1,k-1}(t),$$
 在任一节点区间  $[t_i, t_{i+1}]$  内部,  $N_{i,k}(t)$  任意阶可导, 在节点处  $N_{i,k}(t)$  是  $p-c$  次可导, 其中  $c$  为该节点的重数, 因此降低节点重数可增加 **B** 样条曲线的连续性。

**B 样条曲线:** De Boor-Cox 递推定义 **B** 样条基函数得到一般 **B** 样条曲线的定义式, 见(3-1)式。连接控制顶点  $P_0, P_1, \dots, P_n$  得到多边折线被称为 **B** 样条曲线的特征多边形。**B** 样条曲线很好的克服了贝兹曲线的缺点, 具有充分的灵活性, 易于进行局部修改, 更加逼近特征多边形, 函数阶次也比较低。分析一般 **B** 样条曲线的定义, 其具有以下性质:

- 1) 局部性。  $k$  次 **B** 样条曲线在  $t \in [t_i, t_{i+1}]$  区间上只与  $k$  个控制顶点有关, 因此, 改变  $k$  阶 **B** 样条的一个控制顶点, 只会对以该顶点为中心的相邻的  $k$  段曲线, 不会影响整条曲线。
- 2) 连续性。若给定的  $m+n+1$  个控制顶点互不相重, 则这些控制顶点控制的整条 **B** 样条曲线具有  $n-1$  阶几何连续, 若控制顶点节点重数为  $h$ , 则整条 **B** 样条曲线有  $n-h-1$  阶几何连续。
- 3) 存在导数公式。根据 **B** 样条基函数的微分公式, 可以推算得到公式(3-3) **B** 样条曲线的导数。

$$\begin{aligned}
 P'(t) &= \left( \sum_{i=0}^n P_i N_{i,k}(t) \right)' \\
 &= \sum_{i=0}^n P_i N'_{i,k}(t) \\
 &= (k-1) \sum_{i=0}^n \left( \frac{P_i - P_{i-1}}{t_{i+k-1} - t_i} \right) N_{i,k}(t)
 \end{aligned} \tag{3-3}$$

- 4) 几何不变性。式 (3-1) 为 **B** 样条曲线的定义式，其形状和位置与坐标系的选择无关。
- 5) 保凸性。连接所有控制顶点的折线构成一个平面凸的闭多边形时，**B** 样条曲线是一条平面凸曲线。




图 3-2 一般 **B** 样条曲线的保凸性示意图

- 6) 凸包性。当  $t \in [t_{k-1}, t_{n+1}]$  时，根据 **B** 样条基函数的性质有  $0 \leq N_{i,k}(t) \leq 1$  以及  $\sum_{i=0}^n N_{i,k}(t) = 1$ ，因此，根据凸包的定义可以知道，在  $[t_i, t_{i+1}]$  区间内，**B** 样条曲线必定在连接控制顶点的折线构成的凸包之内。如图 3-3 所示，六个控制顶点控制的三次 **B** 样条由三段 **B** 样条曲线组成，每一段曲线分别落在四个顶点构成的凸包之中。




图 3-3 一般 **B** 样条曲线的凸包性示意图

- 7) 变差缩减性。假设 B 样条曲线的控制顶点有  $n+1$  个，这些控制顶点连接构成 B 样条曲线的特征多边形，则有以下结论：该平面内任意一条直线与该 B 样条曲线交点的个数不过与该直线与特征多边形交点的个数，如图 3-4。




图 3-4 一般 B 样条曲线的变差缩减性

- 8) 直线保持性。控制顶点构成的特征多边形退化成一条直线的时候，B 样条曲线也退化为一根直线。
- 9) 表示唯一性。公式 (3-1) 唯一表示由  $\{P_0, P_1, \dots, P_n\}$  控制顶点特征表示的  $k$  阶 B 样条曲线。

**函数逼近：**函数逼近的概念是在复杂函数用简单函数近似代替研究过程中被提出，函数逼近不要求具体某些点误差为零，如插值近似代替的方法，而是考虑整体的误差限制。对函数类  $A$  中给定的函数  $f(x)$ ，记作  $f(x) \in A$ ，要求在另一类简单的便于计算的函数类  $B$  中求  $p(x) \in B$ ，使得  $p(x)$  与  $f(x)$  的误差在某种度量意义下最小<sup>[20]</sup>。 $f(x)$  为被逼近的函数， $p(x)$  为逼近函数，两者之差为逼近误差。函数类  $A$  通常是区间  $[a, b]$  上的连续函数，记作  $C[a, b]$ ，函数  $B$  通常为  $n$  次多项式、分式有理函数或三角多项式等，在函数逼近空间  $C[a, b]$  中， $f(x)$  可以定义公式 (3-4) 中三种常用的函数范式。

$$\begin{aligned}
 \|f\|_1 &= \int_a^b |f(x)| dx && 1\text{-范数} \\
 \|f\|_2 &= \left( \int_a^b |f(x)|^2 dx \right)^{\frac{1}{2}} && 2\text{-范数} \\
 \|f\|_\infty &= \max_{a \leq x \leq b} |f(x)| && \infty\text{-范数}
 \end{aligned} \tag{3-4}$$



根据 Weierstrass 定理, 则对  $\forall \varepsilon > 0$ , 总存在多项式  $p(x)$ , 使得公式 (3-5) 在区间  $[a, b]$  上一致成立。

$$\max_{a \leq x \leq b} |f(x) - p(x)| < \varepsilon \quad (3-5)$$

LCSCA 是在以上讲述的 B 样条基函数、一般 B 样条函数和函数逼近这三个理论上提出来的。它能够以轨迹点为型值点, 通过 B 样条基函数变化获取表示序列反求轨迹曲线的控制点。该过程简单总结为: 根据目标轨迹的分布趋势, 把轨迹序列  $T = \{(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)\}$  通过非均匀三次 B 样条基函数变换, 得到目标轨迹的表示序列  $F = \{C_1^x, C_2^x, \dots, C_p^x, C_1^y, C_2^y, \dots, C_p^y\}$ , 其中  $p$  为设定的控制点个数; 得到目标轨迹表示序列后, 利用 De Boor-Cox 递推定义的 B 样条基来计算反求控制点的系数矩阵  $\Phi$ , 建立控制点反算方程:  $F^{XY} = \Phi^{\dagger} T^{XY}$ 。

### 3.2.2 基于 LCSCA 的目标轨迹表示

在监控场景中不完整测试轨迹分类前, 由于跟踪时间变化特性造成的轨迹长度不一的问题, 需要对轨迹进行预处理, 保证这些不同长度的轨迹之间有意义的比较。LCSCA 方法中控制顶点和权值因子能够灵活的表示各种形状的曲线, 使用 LCSCA 方法表示目标轨迹, 能够获得相同长度的轨迹表示, 并且表示序列包含了目标运动的方向信息。算法步骤首先根据目标轨迹长度及分布趋势, 构建参数矢量和非均匀节点矢量, 然后根据非均匀节点矢量构造出非均匀 B 样条基函数, 通过对轨迹数据的三维时变序列转换为包含运动方向信息的表示序列, 构建反求控制点的系数矩阵, 最后建立控制点的反算方程。在本文研究中, 采用 LCSCA 方法表示不完整轨迹的具体过程如下:

#### 1) 构造参数矢量和非均匀节点矢量。

根据目标轨迹长度及的分布趋势, 选取与轨迹时间信息相关的弧长比值作为参数矢量  $s = \{0, s_2, \dots, s_{N-1}, s_N\}$ , 见公式 (3-6), 其中  $n = 2, 3, \dots, N$ ,  $s_n \in (0, 1)$ 。

$$s_n = \frac{\sum_{i=2}^n \sqrt{(x_i - x_{i-1})^2 + (y_i - y_{i-1})^2}}{\sum_{i=2}^N \sqrt{(x_i - x_{i-1})^2 + (y_i - y_{i-1})^2}} \quad (3-6)$$

不完整轨迹很短时，运动目标位置变化不大，用上述参数向量的 **B** 样条基函数很小或出现分母为零的情况，可能会影响后面反算控制点的准确性，针对这种情况，当不完整轨迹很短，设定一个阈值，若轨迹长度小于给定的阈值时，以时间帧长度比来定义参数矢量  $s = \{s_1, s_2, \dots, s_n\}$ ，见式 (3-7)，其中  $t$  为当前不完整轨迹的时间帧长度。选定控制顶点的个数  $p$ ，构造公式 (3-8) 非均匀的节点矢量。

$$s_n = \frac{n}{t}, n = 1, 2, \dots, t \quad (3-7)$$

$$(\bar{\tau})_{1 \times (p+4)} = \left\{ \underbrace{0, 0, 0, 0}_{1 \dots 4}, \underbrace{\frac{1}{p-3}, \frac{2}{p-3}, \dots, \frac{p-4}{p-3}}_{5 \dots p}, \underbrace{1, 1, 1, 1}_{p+1 \dots p+4} \right\} \quad (3-8)$$

## 2) 计算 **B** 样条基。

四个控制顶点影响一段三次 **B** 样条曲线，根据以上构建的参数矢量和非均匀节点矢量，可以得到公式 (3-9) 三次 **B** 样条基函数。

$$B_{p,1}(s_n) = \begin{cases} 1 & \text{当 } \tau_p \leq s_n < \tau_{p+1} \text{ 时} \\ 0 & \text{其他} \end{cases} \quad (3-9)$$

$$B_{p,4}(s_n) = \frac{s_n - \tau_p}{\tau_{p+3} - \tau_p} B_{p,3}(s_n) + \frac{\tau_{p+4} - s_n}{\tau_{p+4} - \tau_{p+1}} B_{p+1,3}(s_n)$$

## 3) 构建反求 **B** 样条控制点的系数矩阵。

使用以上 De Boor-Cox 递推得到的 **B** 样条基函数得到反求控制点的系数矩阵，见公式 (3-10)。

$$\Phi = \begin{Bmatrix} B_{1,4}(s_1) & \cdots & B_{p,4}(s_1) \\ \vdots & \ddots & \vdots \\ B_{1,4}(s_N) & \cdots & B_{p,4}(s_N) \end{Bmatrix} \quad (3-10)$$

## 4) 建立反算方程求解控制点序列。

非均匀三次 B 样条基解析表达轨迹数据的过程可以用公式 (3-11) 表示,

$$\begin{aligned}
 \text{其中, 轨迹数据为 } T^{XY} = \begin{bmatrix} x_1 & y_1 \\ \vdots & \vdots \\ x_N & y_N \end{bmatrix}, \text{ 控制点序列为 } F^{XY} = \begin{bmatrix} c_1^X & c_1^Y \\ \vdots & \vdots \\ c_p^X & c_p^Y \end{bmatrix}. \\
 T^{XY} = \Phi \cdot F^{XY} \tag{3-11}
 \end{aligned}$$

目标轨迹的表示控制点序列可以由  $F^{XY} = \Phi^\dagger T^{XY}$  求解, 其中  $\Phi^\dagger$  是  $\Phi$  的伪逆, 由  $\Phi^\dagger = (\Phi^T \Phi)^{-1} \Phi^T$  求得。图 3-5 为监控场景 CAVIAR 数据集<sup>[59]</sup>的行为模式轨迹图, 共 11 类, 区别方向共 22 类, 每类 100 条, 红色为每条轨迹对应的控制点, 可以看到控制顶点一般分布在目标轨迹运动变化的地方, 使用 LCSCA 方法表示目标轨迹能够获得固定长度的轨迹表示, 并且转换后得到的这种参数序列包含轨迹的运动方向等信息。




图 3-5 CAVIAR 场景数据集行为模式轨迹图

### 3.3 局部轨迹样本子集获取

在实际场景中, 不完整目标轨迹往往是长度不一的短轨迹, 仅包含目标的局部运动信息。由于其与场景中代表典型行为模式的完整训练轨迹在长度上相差较大, 在对这些不完整轨迹匹配分类时, 分类效果较差。

为提高不完整轨迹的分类准确性，本文研究中提出构造局部轨迹样本子集用于不完整轨迹匹配分类，这些局部轨迹样本子集是在完整轨迹训练样本基础上按照不完整轨迹测试样本当前时刻位置与 LCSCA 表示的完整轨迹的控制点组位置关系获取，能够在运动形状上与不完整轨迹测试样本最相似。




图 3-6 局部样本子集获取方法示意图

获取局部轨迹样本子集的具体做法是：计算测试不完整轨迹当前时刻轨迹点位置与代表场景中每一种行为模式的完整轨迹训练样本的控制点组的距离，选取距离最近的一组控制点，遍历每个控制顶点对应的轨迹的每个轨迹点，选取离该控制点距离最近的轨迹点截取局部轨迹，最后得到局部轨迹样本子集如图 3-6 所示，蓝色为完整轨迹训练样本集合，红色为描述这些训练样本的 B 样条每一个控制点组的中心位置，绿色为不完整轨迹测试样本， $\{d_1, d_2, d_3, d_4, d_5\}$  为不完整轨迹测试样本当前帧位置与各控制点组中心的距离。

获取局部轨迹样本子集公式见式 (3-12)，其中， $F'_{ji}$  是第  $j$  类第  $i$  组控制点中心， $P_j$  为第  $j$  类轨迹与测试轨迹当前时刻轨迹位置  $T_{test\_frame}$  距离最近的一组控制点， $D$  中每条轨迹与公式 (3-11) 求得的对应的控制点距离最小的轨迹点截取不完整轨迹训练样本，得局部轨迹样本子集。

$$P_j = \arg \min_{i=1, \dots, p} \|T_{test\_frame} - F'_{ji}\|_2 \quad (3-12)$$

### 3.4 实验结果及分析

本文对监控视频中不完整轨迹的分类和预测的研究，主要是在室内监控大厅数据集 CAVIAR 上，建立包含完整轨迹和不完整轨迹的样本数据库，其中完

整轨迹共 2200 条，代表场景中 22 中典型行为模式，每类共 100 条轨迹，不完整轨迹用作研究中的测试样本，共 40 条。以下实验结果是 CAVIAR 数据集示意目标轨迹表示及局部轨迹样本获取。

### 3.4.1 基于 LCSCA 的目标轨迹表示

**实验步骤：** 1) 获取场景中的有效轨迹集合； 2) 设定控制点数值  $p$ ； 3) 用 LCSCA 方法表示目标轨迹。

**算法评估：**

图 3-7 (a) 为场景中第 7 类行为模式轨迹样本的 LCSCA 轨迹表示结果，图 3-7 (b) 是在场景背景下的单条轨迹表示结果，由图中可以看到 LCSCA 轨迹表示方法对于长度不一的轨迹可以获得固定长度的表示，并且对复杂运行行为的目标轨迹也能获得较精确的表示结果。




图 3-7 LCSCA 目标轨迹表示结果

不完整轨迹很短时，目标运动位置变化不大，选取与轨迹时间信息相关的弧长比值作为参数矢量，得到的参数矢量  $S_n$  很小，由  $F^{XY} = \Phi^\dagger T^{XY}$  求得的控制点偏差较大，研究中针对这种情况，在不完整轨迹小于一定阈值时（实验中阈值设定为 40），选用不完整轨迹的帧长比值来表示参数矢量。

图 3-8 (a) 蓝色点为前 30 帧的轨迹点，红色点是以弧长比值做参数向量求得的控制点，图 3-8 (b) 蓝色点为前 30 帧轨迹点，红色点是以时间帧长比值做参数向量求得的控制点。由图中可以看到，不完整轨迹很短时，位置变化不大，

用弧长比值做参数向量的方法求得的控制点位置偏差较时间帧长比值方法大，重构误差也较大。




图 3-8 不完整轨迹两种方法定义参数矢量的轨迹表示结果

### 3.4.2 局部轨迹样本子集获取

**实验步骤：**1) 获取不完整测试轨迹以及场景中完整训练轨迹集合；2) 计算不完整轨迹当前时刻位置与每类行为模式的完整轨迹训练样本每一组控制点中心位置的距离；3) 选取距离最小的控制点组，遍历每一条轨迹上的轨迹点与该轨迹上所选取的控制点的距离，选取距离最小的轨迹点为分界点，将完整轨迹训练样本划分为两个局部轨迹样本子集。

**算法评估：**如图 3-9 所示，图 3-9 (a) 是监控场景中一条完整轨迹，图 3-9 (c) 为第 7 类训练样本和 10 个控制点组，图 3-9 (b) 为该轨迹前 100 帧不完整轨迹，按照上述方法以图 3-9 (c) 绿色控制点组截取获得图 3-9 (d) 的不完整轨迹作为训练样本集。




图 3-9 局部轨迹样本子集获取结果

控制点分布在目标运动轨迹变化较大的地方，这种方法截取不完整轨迹训练集合的优点是可以获得去测试轨迹运动模式相近的不完整轨迹训练样本，提高稀疏重构系数的准确性，降低重构误差。本方法的对比实验采用最长公共子序列方法和按照不完整轨迹测试样本当前时刻轨迹点位置长度截取局部轨迹样本子集。

图 3-10 (a) 是以局部轨迹训练样本做不完整轨迹分类的训练样本集合得到的不完整测试轨迹长度由 20 帧变化到 271 帧的行为类别分布结果，图 3-10 (b) 是以完整轨迹做分类训练样本集合，对不完整测试轨迹直接分类得到的行为类别分布结果，不完整轨迹为第 7 类行为模式的测试样本。可以看到以完整轨迹做训练样本直接对不完整轨迹分类，从 20 帧到 175 帧都得到错误的分类结果，而按照完整轨迹训练样本控制点位置获取局部轨迹训练样本集合再对测试轨迹进行分类能得到更好的分类结果，由此可见，局部轨迹样本方法能够有效提高不

完整轨迹分类的准确性。




图 3-10 局部轨迹训练样本对不完整轨迹分类准确性的影响




图 3-11 局部轨迹样本获取结果

由图 3-10 (a) 可以看到不完整测试轨迹由 20 帧变化到 80 帧过程中，容易把目标轨迹分为第 11 类。主要原因是完整轨迹长度很短时，获取到的部分行为模式类别的局部轨迹样本比较相似，区分性弱。如图 3-11 所示，当不完整



轨迹测试样本长度为 80 帧时,截取得的第 7 类和第 11 类不完整轨迹训练样本集合如图 3-11 (c) 和图 3-11 (d) 所示,可以看到这两类的不完整轨迹,部分轨迹行为模式相似,使得分类时得到错误的分类结果。

### 3.5 本章小结

本章分三部分介绍本文的研究内容,第一部分介绍基于 LCSCA 的目标轨迹表示,为提高不完整轨迹分类的准确性,第二部分介绍在 LCSCA 表示基础上获取局轨迹样本子集,第三部分给出轨迹表示和局部轨迹获取方法实验分析。实验结果验证 LCSCA 目标轨迹表示方法在轨迹长度不一、运动方向多变问题上的有效性,通过对比实验结果验证局部轨迹样本子集能有效提高不完整轨迹分类的准确性。



## 第四章 不完整轨迹分类及预测研究

在上一章 LCSCA 表示目标轨迹基础上,本章主要介绍不完整轨迹分类及预测的研究内容。研究中采用稀疏重构分析算法对测试样本和局部轨迹子集匹配计算,由获得的稀疏重构误差判断测试样本行为模式类别并对齐归一化求倒数计算将来运动方向概率,稀疏重构系数反映测试样本与某一类别行为模式训练样本的相似程度,研究中使用 DTW 方法对齐训练样本,用稀疏重构系数计算不完整测试轨迹当前时刻以后的运动位置。对所采用的研究方法,本章将给出相应的实验结果,通过实验验证所采用的方法可以有效解决轨迹长度不一、不完整轨迹短轨迹分类性能低等问题,并且除预测目标运动方向外,研究所采用方法能够获取不完整轨迹运动行为结束前的比较合理的完整预测轨迹。图 4-1 中蓝色部分为本章所要介绍的内容。

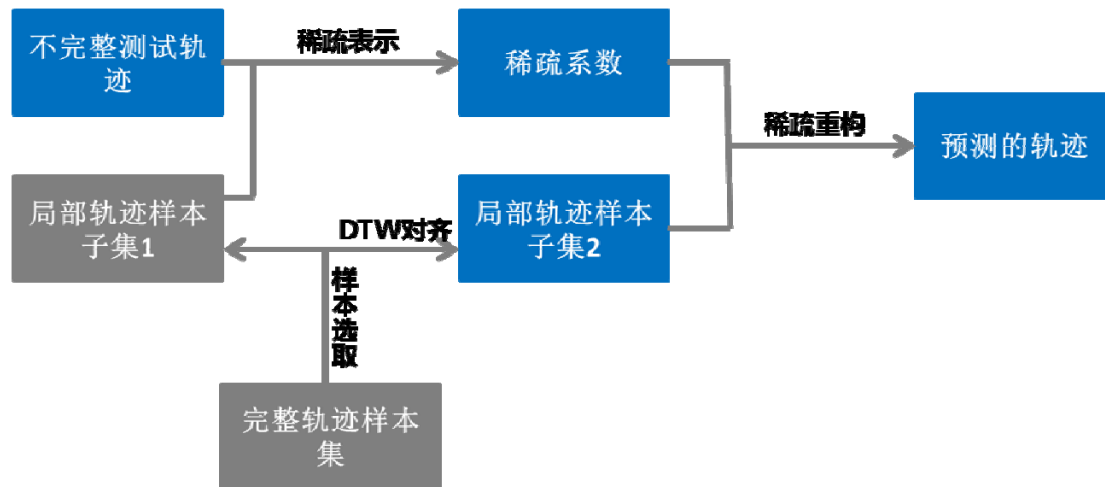


图 4-1 不完整轨迹分类和预测研究框架

### 4.1 不完整轨迹分类

稀疏重构在信号处理、模式识别和图像处理领域的迅速发展和其良好的抗噪性,本节在 Li<sup>[57]</sup>研究工作基础上,将稀疏重构理论用于实现不完整轨迹行为模式分类。不完整轨迹仅包含目标的局部运动信息,与完整轨迹训练样本长度相差较大,严重影响模型的分类性能。为解决这个问题,本文使用 LCSCA 方法表示不完整轨迹测试样本和完整轨迹训练样本,得到完整轨迹训练样本 LCSCA

轨迹表示的控制顶点后，计算不完整测试轨迹当前时刻位置与代表各类行为模式的完整轨迹训练样本每组控制顶点中心位置的关系，选取距离最近的一组控制点截取该类行为模型的局部轨迹样本子集，并以此子集作为用于稀疏重构分类的训练集合。

#### 4.1.1 稀疏重构分析

稀疏重构分析近几年来再信号处理、机器学习以及模式识别等领域得到了很多研究人员的青睐，该算法建立在压缩感知理论上。压缩感知理论由 D.Donoho、E.Candes 及华裔科学家陶喆轩等人提出<sup>[60]</sup>，它主要包括三个方面的内容，分别是信号的稀疏表示、随机测量和重构算法。建立在此基础上的稀疏重构分析是指，当信号在某个变换域是稀疏的或可压缩的，可以利用与变换矩阵非相干的测量矩阵将变换系数线性投影为低维观测向量，同时这种投影保持了信号重建时所需的信息，通过进一步求解稀疏优化问题就能够从低维观测向量精确地或高概率精确地重建原始信号<sup>[20]</sup>。

信号的稀疏表示，一般是指信号在一个过完备的基上的表示是稀疏的。稀疏是指集合中大部分元素为 0，这样使得信号能量集中在少数非零的元素上，这些非零的元素可以反映信号的主要特征和内在结构。近几年来，稀疏表示的研究的一个热点是利用冗余字典对信号稀疏表示，使用超完备的冗余函数库取代基函数，新的信号可以表示成冗余字典中信号元素的线性组合。简单概括稀疏重构的研究问题是，信号能否稀疏表示，如果可以，用什么样的模型进行表示，如果求解该模型。压缩感知理论对于该问题使用 0-范数的稀疏重构模型，见公式 (4-1)，其中  $A$  为测量矩阵， $x$  为集合中非零元素的系数即信号的稀疏表示系数， $y$  是信号重构的结果。 $\|\bullet\|_0$  为 0-范数，表示系数向量非零项的个数。

$$\min_x \|x\|_0 \quad s.t. \quad y = Ax \quad (4-1)$$

通过公式(4-1)，压缩感知信号稀疏重构问题转化为求 0-范数最小化问题。然而 0-范数最小化问题是一个 NP-hard 问题，通常需要对该问题加以转化。陶喆轩和 Candes 于 2007 年<sup>[61]</sup>建立了著名的约束等距性(Restricted Isometry Property,

RIP) 理论, 该理论证明若使信号完全重构, 必须满足稀疏度的解释满足 1-范数最小的向量, 即在 RIP 条件下, 0-范数最小化问题与下式中 1-范数最小化问题有相同的解, 于是可以将 NP-hard 的 0-范数最小化问题转化为公式 (4-2) 求解较为简单的 1-范数最小化问题。

$$\min_x \|x\|_1 \quad s.t. \quad y = Ax \quad (4-2)$$

RIP 性质提出以后, 稀疏表示和重构先后被应用到模式识别和计算机视觉等领域中, 此基础上, 很多稀疏重构的求解方法被相继提出, 目前这些求解方法主要可以分为三类: 贪婪算法、凸优化算法和迭代阈值法。

- 1) 贪婪算法: 这类算法直接对 0-范数进行最小化求解, 通过选择合适的原子并经过一系列的逐步递增的方法实现对信号的逼近, 这类算法的典型代表有 MP (Matching Pursuit, 匹配追踪) 方法<sup>[62]</sup>, 和 OMP (Orthogonal Matching Pursuit, 正交匹配追踪) 方法<sup>[63]</sup>等。
- 2) 凸优化算法: 这类算法将 0-范数最小化问题转化为求 1-范数最小化问题, 通过线性规划求解。这类方法在当前研究中比较热门, 常见的有 OPSR (Gradient Projection for Sparse Reconstruction, 梯度投影稀疏重构) 方法<sup>[64]</sup>、BP (Basic Pursuit, 基追踪) 方法<sup>[65]</sup>和 Bregman 迭代法等。
- 3) 迭代阈值法: 也被称为 LASSO 方法<sup>[66]</sup>, 该方法建立最小二乘误差和 1-范数正则化的约束模型, 使用贪婪算法求解模型, 此类算法通过不断松弛模型中的阈值  $\varepsilon$ , 来实现迭代求解。

$$\min_x \|Ax - y\|_2 \quad s.t. \quad \|x\|_1 \leq \varepsilon \quad (4-3)$$

稀疏重构理论不断发展突破, 得到了信号处理、图像处理、模式识别等领域研究人员的极大关注, 大量相关研究成果被发表。基于本文的研究目的, 简要介绍稀疏重构在图像处理领域的应用。John Wright 等<sup>[67]</sup>提出对新的人脸测试样本使用训练样本集合进行 1-范数最小化的线性稀疏表示, 根据得到的稀疏系数向量来求解最小稀疏重构误差, 实现人脸识别。Yang 等<sup>[68]</sup>在高分辨率图像和低分辨图像中简历两组对应的基, 根基高低分辨率之间的对应性, 实现超分辨

率重建。Li 等<sup>[57]</sup>监控场景中，对测试轨迹使用训练轨迹样本进行 1-范数最小化的线性稀疏表示，通过求解最小化重构误差，判断测试轨迹的行为是否异常。

#### 4.1.2 基于稀疏重构分析的不完整轨迹分类

将监控场景中完整轨迹训练集以及前面用 LCSCA 目标轨迹表示部分获得的局部轨迹样本子集，按不同行为模式分别建立完整训练样本集合  $A_j = \{a_j^1, a_j^2, \dots, a_j^K\}$ 、局部轨迹样本子集  $B_j = \{b_j^1, b_j^2, \dots, b_j^K\}$ 、局部轨迹样本子集  $C_j = \{c_j^1, c_j^2, \dots, c_j^K\}$ ， $K$  为第  $j$  种行为模式的轨迹样本数目。将局部轨迹样本子集  $B_j$  合并，得到公式 (4-4) 用于不完整轨迹测试样本匹配分类的训练样本集合，其中， $J$  表示监控场景中典型行为模式的个数，由此可以得到一个  $K \times J$  条局部轨迹样本的行为模式集合。

$$D = \cup\{B_j\} = \{b_1^1, b_1^2, \dots, b_1^K, b_2^1, b_2^2, \dots, b_2^K, \dots, b_J^1, b_J^2, \dots, b_J^K\}, j = 1 \dots J \quad (4-4)$$

定义特征函数  $\delta_j$ ， $\delta_j$  只保留  $D$  中第  $j$  种局部轨迹样本所对应的稀疏系数(由公式 (4-5) 计算所得)，而将其他类型的局部轨迹样本随对应的稀疏系数置 0。由以上定义，可以将不完整轨迹  $T_{test}$  与  $D$  中局部轨迹样本进行公式 (4-7) 所示的匹配分类，公式 (4-5) 中  $\psi$  用于表示测试的不完整轨迹  $T_{test}$  基于局部轨迹样本训练集合  $D$  的重构稀疏系数  $\psi = \{\psi_j^k\}$ ， $j = 1, \dots, J, k = 1, \dots, K$ ， $\psi_j^k$  表示集合  $D$  中第  $j$  种行为模式的第  $k$  个样本对应的重构稀疏系数，式 (4-7) 将不完整测试轨迹行为判定为重构误差最小的第  $j$  中行为模式。

$$D\psi \approx T_{test} \quad (4-5)$$

$$\arg \min \|\psi\|_1, \text{ s.t. } D\psi = T_{test} \quad (4-6)$$

$$\text{Classify}(T_{test}) = \underset{j}{\operatorname{argmin}} r_j(T_{test}) = \|T_{test} - D\delta_j(\psi)\|_2 \quad (4-7)$$

## 4.2 不完整轨迹分类实验

**实验步骤：**1) 读入不完整测试轨迹  $T_{test}$ 、局部轨迹样本子集  $D$ ；2) 使用  $D$  计算不完整测试轨迹的稀疏重构系数  $\psi$ ；3) 计算每一类稀疏重构误差，判定测

试轨迹行为模式类别。

### 算法评估:

在上一章中根据不完整轨迹阈值定义参数向量对目标轨迹进行表示的基础上,本章介绍了基于稀疏重构分析方法的不完整轨迹分类和预测。实验通过逐帧增加不完整轨迹长度,考察不同长度的不完整轨迹对分类准确性的影响,并且分析对不同控制点个数描述轨迹曲线对分类结果的影响。

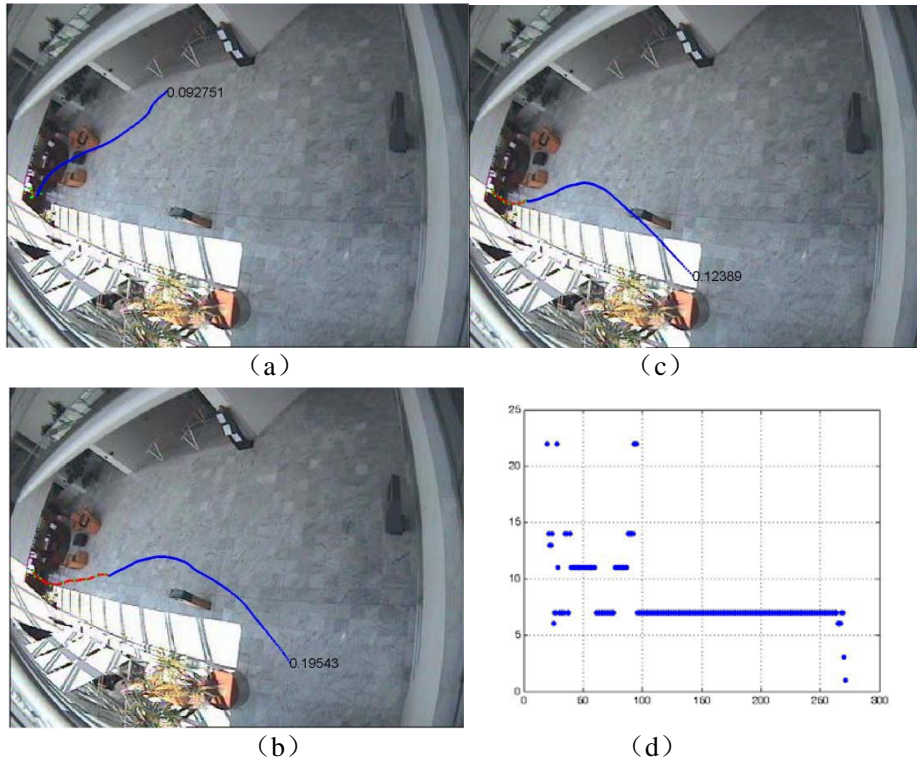


图 4-2 基于稀疏重构分析的不完整轨迹分类

如图 4-2 所示,由左到右上到下的顺序依次是 21 帧不完整轨迹、98 帧不完整轨迹、155 帧不完整轨迹的分类预测概率以及逐帧加长的不完整轨迹用上述分类方法求得的类别标号分布,可以看到在轨迹不完整很短的情况下,由于每一类的重构系数差别不大,使得在根据重构误差进行类别判断时无法正确分类,随着不完整轨迹不断加长,各类间的重构系数区别性增强,所属类别的重构误差减小,不完整轨迹得以正确分类。

当不完整轨迹测试样本长度为 80 帧时,截取得到第 7 类和第 11 类不完整轨

迹训练样本集合如图 4-3(c)和图 4-3(d)所示，可以看到这两类的不完整轨迹，部分轨迹行为模式相似，这导致两类的重构系数区别不大，导致出现图 4-2(d)中类别标号被错分的结果，当轨迹长度从 20 帧左右逐帧增加变化到 80 帧左右，不完整测试轨迹判定的类别标号分布如图 4-4 所示，由图中可以看到不完整轨迹的类别判断为第 7 类与第 11 类概率基本相等。




图 4-3 不完整轨迹长度为 80 帧时第 7 类和第 11 类的完整轨迹训练集

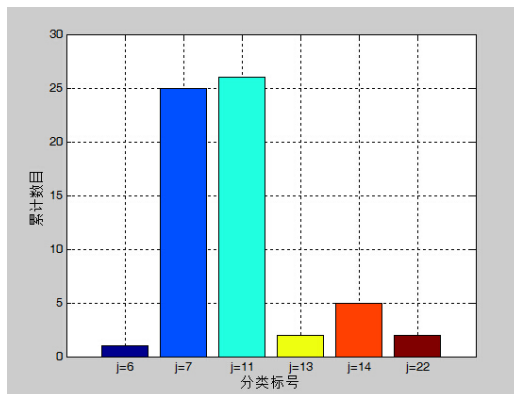


图 4-4 不完整轨迹长度由 20 帧变化到 80 帧类别判断统计



当不完整测试轨迹长度由 21 帧变化到 271 帧时，分类判别统计如图 4-5 所示，可以看出，随着不完整轨迹逐帧增加加长，从 80 帧起，目标轨迹基本能够被正确分类。




图 4-5 不完整轨迹长度变化时分类统计及正确分类概率变化




图 4-6 不同控制点不同长度测试轨迹的正确分类的概率

如图 4-6 所示为不同控制点个数描述轨迹和不同长度测试轨迹的正确分类概率，用于验证不同控制点个数的轨迹描述方式以及不同长度测试轨迹对于稀疏重构理论下轨迹分类和行为预测的有效性。其中，不同测试轨共 21 条，可以看到，测试轨迹从 60 帧变化到 120 帧。同时正确分类的概率增大。同时，通过

图示克制，控制点为 5 时分类效果最好，因此，在求解稀疏重构系数时，择优选择表示目标轨迹的控制点数目为 5。

### 4.3 不完整轨迹预测

当前基于行为模式学习的轨迹预测研究工作大多是得到运动目标属于某种行为模式的概率，只能预测其将来的运动方向或者将来很短时间内的运动位置，并不能得到未来长时间内的轨迹预测结果。本文研究采用系数重构分析方法对不完整轨迹匹配分类过程中获得的稀疏重构误差以及稀疏重构稀疏，不仅能得到运动运动目标属于某种行为模式的概率值，由于稀疏重构系数反映不完整轨迹测试样本与代表某种行为模式训练轨迹之间的相似程度，因此利用稀疏重构系数还能计算得到运动目标未来长时间内的预测轨迹。

#### 4.3.1 基于 DTW 的不完整轨迹对齐

动态时间规整 (Dynamic Time Warping, DTW) 把时间规整和距离测量结合起来，选定参考模板时间序列，把测试模板延长或者缩短，直到与参考模板长度一致。动态时间规整是个优化问题<sup>[69]</sup>，求解两个模板特征量匹配时累积距离最小的规整函数，最后得到累积距离最短的规整路径。如图 4-7 所示，时间序列  $S = s_1, s_2, \dots, s_i, \dots, s_n$ ， $Q = q_1, q_2, \dots, q_j, \dots, q_m$ ，长度分别为  $n$ ， $m$ ，匹配求解累积距离最小，得到规整路径： $W = w_1, w_2, \dots, w_k, \dots, w_K$ ，其中  $\max(n, m) \leq K \leq n + m$ ， $w_k$  的形式为  $(i, j)$ ，最后得到公式 (4-8) 的最短的规整路径。匹配过程必须保证  $W$  中  $w(i, j)$  的  $i$  和  $j$  是单调递增的，即保证时间先后顺序。

$$D(i, j) = d(i, j) + \min[D(i-1, j), D(i, j-1), D(i-1, j-1)] \quad (4-8)$$

$$w_k = w(i, j), w_{k+1} = (i', j') \quad i \leq i' \leq i+1, j \leq j' \leq j+1 \quad (4-9)$$

本文工作中采用的室内 CAVIAR 数据集，重构测试样本行为轨迹时，训练样本集合轨迹长短不一，取每种行为模式轨迹中长度最长的作为该类的匹配模板，匹配过程中若模板的轨迹点重复，则去掉对重复轨迹点对应的测试模板的轨迹点，这样遍历完一类轨迹得到以该类中最长轨迹长度作为对齐长度的重构

数据集，并且不影响两个模板对应轨迹点的相似性，匹配原理示意如 4-8 所示，其中  $S$  为匹配模板， $*$  为模板重复的轨迹点，则把测试轨迹中与  $*$  对应的轨迹点去掉。

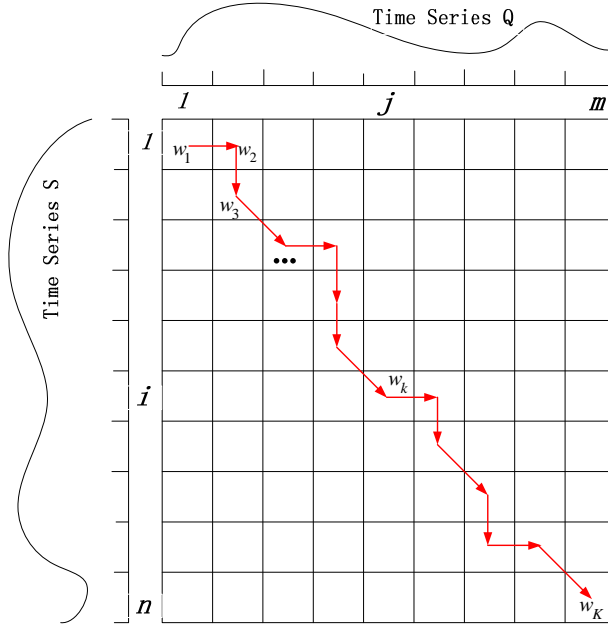


图 4-7 DTW 累积距离矩阵和最短路径




图 4-8 DTW 对齐示意图

### 4.3.2 基于稀疏重构分析的不完整轨迹预测

将局部轨迹样本子集和不完整测试轨迹应用稀疏重构理论得到稀疏重构系数  $\psi$  以及重构误差  $r(j)$ ，重构误差越小，不完整轨迹为第  $j$  类行为模式的概率越大，重构误差取倒数归一化后得到不完整测试轨迹属于第  $j$  类行为的预测概率，见公式 (4-10)。

$$Pobb(j) = \frac{1/r(j)}{\sum_{j=1}^J 1/r(j)} \quad (4-10)$$

使用 DTW 方法对齐前面 LCSCA 目标轨迹表示部分获得的局部轨迹样本子集  $C_j = \{c_j^1, c_j^2, \dots, c_j^K\}$  用于计算预测轨迹的训练样本集合  $C'_j = \{c_j^1, c_j^2, \dots, c_j^K\}$ ，由式 (4-11) 及公式 (4-12) 计算得到预测的轨迹，其中式 (4-11) 得到重构误差最小的行为模式类别标号  $label\_j$ ，式 (4-12) 使用 DTW 对齐后的局部样本子集中重构误差最小的行为模式类别的轨迹与对应的系数重构系数相乘得到不完整测试样本的预测轨迹。

$$label\_j = \underset{j}{\operatorname{argmin}} r_j(T_{test}) = \|T_{test} - D\delta_j(\psi)\|_2 \quad (4-11)$$

$$T\_pre = C'_{label\_j} \delta_{label\_j}(\psi) \quad (4-12)$$

如图 4-9 所示，使用 DTW 方法对齐  $K$  个训练样本集合，由稀疏重构分析方法得到的系数重构系数  $\{w_1, w_2, \dots, w_{k-1}, w_k, \dots, w_{K-1}, w_K\}$  反映测试样本  $T_{test}$  与训练样本之间的相似程度，不完整轨迹测试样本与每一类行为模式训练轨迹的稀疏重构系数相乘得到预测的轨迹点。




图 4-9 不完整轨迹预测模型

### 4.3.3 不完整轨迹预测实验

**实验步骤：**1) 局部轨迹样本子集  $C_j$  和不完整轨迹测试样本；2) 使用 DTW 算法对齐  $C_j$  中的样本轨迹；3) 计算重构误差最小的行为模式类别；4) 将对齐后的局部轨迹样本  $C_j$  重构误差最小的行为模式的轨迹与其对应的稀疏重构系数相乘得到不完整测试样本的预测轨迹。

#### 算法评估：

局部轨迹样本子集对轨迹预测的影响。图 4-10 (a) 是使用局部轨迹样本子集作为分类训练样本的 164 帧长的不完整轨迹预测结果，图 4-10 (b) 是使用完整轨迹训练样本进行 164 帧长的不完整轨迹分类的轨迹预测结果。可以看到使用完整轨迹训练样本分类时，最小化重构误差得到测试样本的行为模式类别为第 11 类，见图 3-10 (b)，不完整测试轨迹被错误分类；运动方向预测概率为 0.059694。同样长度的不完整测试轨迹在局部轨迹样本子集上分类预测，不仅能得到正确的行为模式分类，并且运动方向预测的概率准确性大大提高，得到的预测轨迹也比图 4-10 (b) 的预测轨迹更合理。



图 4-10 局部轨迹样本子集方法对轨迹预测的影响

不完整轨迹测试样本长度对轨迹预测的影响。图 4-11 中描述轨迹的控制点个数为 5，(a)、(b)、(c)、(d) 分别是不完整轨迹长度为 13 帧、54 帧、105 帧、144 帧情况下 DTW 方法对齐训练样本后，利用稀疏重构系数和不完整轨迹相乘得到的轨迹预测结果。可以看到，随着不完整轨迹长度增加，其运动信息表征在轨迹形状上能够区别不同的行为模式，稀疏重构误差最小得到不完整测试轨

迹所述的行为模式类别的概率增大，同时得到的训练样本对应的稀疏重构系数数值比其他类别的训练样本轨迹的大。




图 4-11 不同长度的不完整轨迹预测实验结果



图 4-12 稀疏重构系数反映测试样本与训练样本的相似度

稀疏重构系数反映测试样本与训练样本的相似度。如图 4-12 所示，利用稀疏重构误差得到不完整测试轨迹属于某种行为模式的概率后，不完整轨迹测试样本属于第 7 类行为模式，该类内训练样本对应的稀疏重构系数比其他行为模

式类别的训练样本大，利用稀疏重构系数与测试样本轨迹点相乘得到的预测轨迹更准确。

监控场景中障碍物对不完整轨迹预测的影响。图 4-13 (a) 为场景中第 7 类行为模式的训练样本，由于场景中木墩障碍物的存在，大多数运动目标会从左边绕过障碍物行走，也有少数目标由右边绕过障碍物，如图 4-13 (b) 中黄色轨迹所示运动目标的行走路线，这样在得到测试样本属于第 7 类行为模式后，该类内由右边绕过障碍物的训练样本的稀疏重构系数比从左边绕过障碍物的大，在利用该类所有训练样本稀疏重构系数与测试样本轨迹点相乘加和平均得到的预测轨迹会从左侧绕过障碍物，如图 4-13 (b) 中蓝色轨迹预测结果。



图 4-13 监控场景中障碍物对不完整轨迹预测的影响

不同对齐方法对预测轨迹计算的影响。根据稀疏重构方法求得不完整轨迹分类的重构系数及行为模式分类概率后，使用动态时间规整对齐重构轨迹训练集合，使得样本轨迹长度一致。已完成动态时间规整对齐重构轨迹训练集合以及按照重构轨迹训练样本中最短长度轨迹截取使得重构轨迹集合长度相等。根据前面动态时间规整部分说明，动态时间规整方法对齐轨迹不会破坏轨迹之前的相似性，而直接按最短轨迹时间帧长截取可能会破坏轨迹之间的相似性，使得出现图 4-14 所示结果，描述轨迹控制点个数为 5，不完整轨迹长度是 100 帧，其中图 (a) 为使用 DTW 对齐样本计算得到的预测轨迹，图 (b) 为按照最短轨迹时间帧长度截取获得训练样本集合的结果，从轨迹预测的概率和预测轨迹点的分布与黄色表示的目标真实运动轨迹相比较，可以看出动态时间规整对齐后

轨迹重构的比直接截取的更接近目标的真实运动轨迹。



图 4-14 基于 DTW 对齐轨迹和按最短轨迹直接截取得到轨迹预测结果

#### 4.4 本章小结

本章共分为三部分内容，第一部分首先介绍了基于稀疏重构分析的不完整轨迹分类，通过最小化稀疏重构误差得到不完整测试轨迹的行为模式类别；第二部分在不完整轨迹分类的基础上，由稀疏重构系数，通过动态时间规整对齐训练轨迹，计算不完整轨迹的预测结果；第三部分内容是不完整轨迹分类和预测的实验分析，通过实验验证局部样本子集获取、不完整轨迹长度、描述轨迹控制点个数等因素对分类结果的影响，实验分析影响不完整轨迹预测的因素。本章内容通过实验验证采用局部轨迹样本子集对提高不完整轨迹分类和获取合理预测轨迹的有效性。



## 第五章 总结与期望

本文对不完整轨迹的分类和预测研究，采用 LCSCA 方法表示目标轨迹，按照测试样本当前轨迹点与训练样本控制点组中心位置关系获取局部样本子集，在此基础上通过稀疏重构分析的方法来获得不完整轨迹的行为模式类别并预测其将来的行进轨迹。基于运动目标行为模式的轨迹预测通常会面临下面几个问题：轨迹长短不一、目标运动形状多变、短轨迹运动信息不完整导致分类性能较差、实际样本集较小、只能预测运动方向、难以获取测试轨迹未来长时间内的预测轨迹等。

本文开始先介绍了轨迹分类和预测的研究背景和意义、国内外研究现状和已有的研究方法。分析了轨迹分类和预测的研究中存在的问题以及发展趋势，简要介绍本文的主要研究内容及研究方法；接着分析已有当前研究方法的优劣势，采用基于 LCSCA 的目标轨迹表示方法，针对不完整轨迹长度与完整轨迹相差较大，运动信息不完整，为提高不完整轨迹分类的准确性，提出按照不完整测试轨迹当前时刻位置与各类行为模式完整训练轨迹 B 样条控制点组中心位置关系获取局部轨迹样本子集作为不完整测试轨迹分类和预测研究的训练样本集合，获取的局部样本子集在运动形状上与测试样本最大程度相似。在 LCSCA 目标轨迹表示及样本集构造的研究工作基础上，为使目标轨迹能够用样本集中相关性较大（系数非零）的样本来对目标轨迹进行重构，获取一个反映不完整测试轨迹与训练样本轨迹相似程度的参数，研究中提出基于稀疏重构分析的不完整轨迹分类和预测算法。LCSCA 目标轨迹表示以及基于稀疏重构分析的不完整轨迹分类及预测的研究主要在 CAVIAR 室内监控场景目标轨迹数据集上验证采用的研究方法，实验结果表明，LCSCA 轨迹表示方法可以获得固定长度的轨迹表示，得到的表示序列包含了目标的运动方向信息，解决了轨迹长度不一，运动形状多变的问题；采用局部轨迹样本子集作为不完整轨迹分类和预测的训练样本集合，可以有效提高不完整轨迹分类的准确性；基于稀疏重构分析的不完整轨迹分类及预测能够得到比较鲁棒的分类效果并且能够获得目标在将来较长

时间内比较合理的预测轨迹。

本文采用的算法对不完整轨迹分类和预测研究取得了一定的成功，但仍然存在一些不足。例如 LCSCA 目标轨迹算法中的控制点个数的优化选择；不完整轨迹长度很短的情况下，目标运动位置变化不大，这时的轨迹分类效果不是很理想；研究工作主要在单一的数据集上验证研究方法的有效性，缺少在其他数据集上的算法性能分析；基于行为模式学习的轨迹预测本文采用基于稀疏重构分析的不完整轨迹分类和预测算法虽然能够获得较为合理的预测轨迹，但由于目前预测轨迹计算的研究工作比较少，本文轨迹预测计算工作缺乏他人研究成果的对比。在将来的研究工作中，针对上述存在的问题，我们希望在不完整轨迹很短时，找到能精确的轨迹表示方法以提高分类的准确性，考虑稀疏重构与其他方法相结合，提高算法的鲁棒，将不完整轨迹分类及预测的研究工作做成实时工作的系统。

## 参考文献

- [1] A. Lipton, H. Fujiyoshi, and R. Patil, Moving target classification and tracking from real-time video[C]. In: *Proceeding of 4th IEEE Workshop on Applications of Computer Vision*, 1998: 8-14.
- [2] C. Wren, A. Azarbayejani, T. Darrell, and A. Pentland, Pfinder: Real-time tracking of the human body[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1997, 19(7): 780-785.
- [3] D. Ayers and M. Shah, Monitoring human behavior from video taken in an office environment[J]. *IEEE Transactions on Image and Vision Computing*, 2001, 19(12): 833-846.
- [4] T. Boult, R. Micheals, X. Gao, and M. Eckmann, Into the woods visual surveillance of on-cooperative camouflaged targets in complex outdoor settings[J]. *Proceeding of the IEEE*, 2001, 89(10): 1382-1402.
- [5] C. Bregler, Learning and recognising human dynamics in video sequences[C]. In: *Proceeding of IEEE Conference on Computer Vision Pattern Recognition*, 1997: 568-574.
- [6] A. Lipton, T. Kanade, H. Fujiyoshi, et al. A system for video surveillance and monitoring[M]. Pittsburg: Carnegie Mellon University, the Robotics Institute, 2000: 37-68.
- [7] I. Haritaoglu, D. Harwood, and L. Davis, Real-time surveillance of people and their activities[J]. *IEEE Transaction on Pattern Analysis and Machine Intelligence*, 2000, 22(8): 809-830.
- [8] T. Horprasert, D. Harwood, and L. Davis, A robust background subtraction and shadow detection[C]. In: *Proceeding of Asian Conference on Computer Vision*, 2000: 983-988.
- [9] Y. Ivanov and A. Bobick, Recognition of visual activities and interactions by stochastic parsing[J]. *IEEE Transaction on Pattern Analysis Machine Intelligence*, 2000, 22(8): 852-872.
- [10] N. Johnson and D. Hogg, Learning the distribution of object trajectories for event recognition[J]. *IEEE Transaction on Image and Vision computing*, 1996, 14(8): 609-615.
- [11] W. Hu, D. Xie and T. Tan, A hierarchical self-organizing approach for learning the patterns of motion trajectories[J]. *IEEE Transactions on Neural Networks*, 2004, 15(1): 135-144.
- [12] B. T. Morris and M. M. Trivedi, Learning and classification of trajectories in dynamic scenes: A general framework for live video analysis[C]. In: *Proceeding of IEEE Conference on Advanced Video and Signal Based Surveillance*, 2008: 154-161.
- [13] X. Wang, X. Ma, and E. Grimson, Unsupervised activity perception by hierarchical bayesian models[C]. In: *Proceeding of IEEE Conference on Computer Vision Pattern Recognition*, 2007: 1-8.
- [14] A. Naftel and S. Khalid, Classifying spatiotemporal object trajectories using unsupervised learning in the coefficient feature space[J]. *Multimedia Systems*, 2006, 12(3): 227-238.
- [15] T. Jebara, R. Kondor, and A. Howard, Probability product kernels[J]. *The Journal of Machine Learning Research*, 2004, 5: 819-844.
- [16] R. R. Sillito, and R. B. Fisher. Parametric trajectory representations for behaviour

- classification[J]. *Multimedia Systems*, 2006, 12: 227-238.
- [17] F. Bashir, W. Qu, A. Khokhar, and D. Schonfeld, HMM-based motion recognition system using segmented PCA[C]. *In: Proceeding of IEEE Conference on Image Processing*, 2005, 3: III-1288-91.
- [18] C. Piciarelli and G. L. Foresti, On-line trajectory clustering for anomalous events detection[J]. *Pattern Recognition Letters*, 2006, 27(15): 1835-1842.
- [19] W. Hu, X. Xiao, Z. Fu, D. Xie, T. Tan, and S. Maybank, A system for learning statistical motion patterns[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2006, 28(9): 1450-1464.
- [20] 李策. 基于轨迹分析的视觉目标异常行为检测算法研究[D]. 中国科学院研究生院硕士学位论文, 2012.
- [21] W. Hu, T. Tan, L. Wang, and S. Maybank, A survey on visual surveillance of object motion and behaviors[J]. *IEEE Transactions on Systems, Man, and Cybernetics, Part C: Applications and Reviews*, 2004, 34(3): 334-352.
- [22] D. Makris and T. Ellis, Path detection in video surveillance[J]. *Image and Vision Computing*, 2002, 20(12): 895-903.
- [23] D. Makris and T. Ellis, Learning semantic scene models from observing activity in visual surveillance[J]. *IEEE Transactions on Systems, Man, and Cybernetics, Part B: Cybernetics*, 2005, 35(3): 397-408.
- [24] W. Hu, D. Xie, Z. Fu, W. Zeng, and S. Maybank, Semantic-based surveillance video retrieval[J]. *IEEE Transaction on Image Process*, 2007, 16(4): 1168-1181.
- [25] X. Li, W. Hu, and W. Hu, A coarse-to-fine strategy for vehicle motion trajectory clustering[C]. *In: Proceeding of IEEE Conference on Pattern Recognition*, 2006: 591-594.
- [26] I. N. Junejo, O. Javed, and M. Shah, Multi feature path modeling for video surveillance[C]. *In: Proceeding of IEEE Conference on Pattern Recognition*, 2004: 716-719.
- [27] X. Wang, X. Ma, and E. Grimson, Unsupervised activity perception by hierarchical bayesian models[C]. *In: Proceeding of IEEE Conference on. Computer Vision Pattern Recognition*, 2007: 1-8.
- [28] H. Zhong, J. Shi, and M. Visontai, Detecting unusual activities in video[C]. *In: Proceeding of IEEE Conference on Computer Vision Pattern Recognition*, 2004: 819-826.
- [29] J. Melo, A. Naftel, A. Berardino, and J. Santos-Victor, Detection and classification of highway lanes using vehicle motion trajectories[J]. *IEEE Transaction on Intelligence Transportation Systems*, 2006, 7(2): 188-200.
- [30] A. Naftel and S. Khalid, Motion trajectory learning in the DFT-coefficient feature space[C]. *In: Proceeding of. IEEE Conference on Computer Vision System*, 2006: 47-54.
- [31] J. Lin, M. Vlachos, E. Keogh, and D. Gunopulous, Iterative incremental clustering of time series[M]. *Advances in Database Technology*, 2004: 106-122.
- [32] F. Porikli, Learning object trajectory patterns by spectral clustering[C]. *In: Proceeding of. IEEE Conference on Multimedia Expo.*, 2004, 2: 1171-1174.

- [33] D. Biliotti, G. Anotonini, and J. P. Thiran, Multi-layer hierarchical clustering of pedestrian trajectories for automatic counting of people in video sequences[C]. *In: Proceeding of IEEE Workshop Application of Computer Vision*, 2005: 50–57.
- [34] M. Bennewitz, W. Burgard, and G. Cielniak, Utilizing learned motion patterns to robustly track persons[C]. *In Proceeding of IEEE Workshop Visual Surveillance Performance Evaluation of Tracking and Surveillance*, 2003: 102–109.
- [35] B. T. Morris and M. M. Trivedi, Learning, modeling, and classification of vehicle track patterns from live video[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2008, 9(3): 425-437.
- [36] N. Sumpter and A. J. Bulpitt, Learning spatio-temporal patterns for predicting object behaviour[J]. *Image and Vision Computing*, 2000, 18(9): 697-704.
- [37] C. Stauffer and W. E. L. Grimson, Adaptive background mixture models for real-time tracking[C]. *In: Proceeding of IEEE Conference on Computer Vision and Pattern Recognition*, 1999: 246–252.
- [38] H. Zhong, J. Shi, and M. Visontai, Detecting unusual activities in video[C]. *In: Proceeding of IEEE Conference on Computer Vision and Pattern Recognition*, 2004, 2: 819–826.
- [39] Ephraim Y, Merhav N. Hidden markov processes[J]. *IEEE Transactions on Information Theory*, 2002, 48(6): 1518-1569.
- [40] Bilmes J. What HMMs can do[J]. *IEICE transaction on Information and Systems*, 2006, 89(3): 869-891.
- [41] N.M. Oliver, B. Rosario, and A.P. Pentland. A bayesian computer vision system for modeling human interactions[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2000, 22(8): 831-843.
- [42] T.V. Duong, H.B. Bui, D.Q. Phung, and S. Venkatesh, Activity recognition and abnormality detection with the switching Hidden Semi-Markov Model[C]. *In: Proceeding of IEEE Conference on Computer Vision and Pattern Recognition*, 2005: 838-845.
- [43] V. Dizan, F.Thierry, and L. Christian, Growing Hidden Markov Models: an incremental tool for learning and predicting human and vehicle motion[J]. *International Journal of Robotics Research*, 2009: 11-12.
- [44] V. Vapnik and A. Lerner, Pattern recognition using generalized portrait method[J]. *Automation and remote control*, 1963, 24: 774-780.
- [45] B. Boser, I. Guyon, and V. Vapnik, A training algorithm for optimal margin classifiers[C]. *In: Proceeding of 5th annual workshop on Computational learning theory*, 1992: 144-152.
- [46] B. Scholkopf, J.C. Platt, J. Shawe-Taylor, A.J. Smola, and R.C. Williamson, Estimating the Support of A High-dimensional Distribution[J]. *Neural computation*, 2001: 1443-1471.
- [47] C. Piciarelli, C. Micheloni, and G.L. Foresti, Trajectory-based anomalous event detection[J]. *IEEE Transactions on Circuits and Systems for Video Technology*, 2008: 1544-1554.
- [48] C. Stauffer, and W.E.L. Grimson. Learning patterns of activity using real-time tracking[J]. *IEEE Transaction on Pattern Analysis and Machine Intelligence*, 2000, 22(8): 747-757.

- [49] J.C. Bezdek, Pattern recognition with fuzzy objective function algorithms[M]. Kluwer Academic Publishers, 1981.
- [50] 刘洋. 基于视觉的车辆路面行为分析关键技术研究 [D]. 中国科学院研究生院硕士学位论文, 2010.
- [51] N. Johnson and D. Hogg, Learning the distribution of object trajectories for event recognition[J]. *Image and Vision computing*, 1996, 14(8): 609-615.
- [52] R. R. Sillito, and R. B. Fisher, Semi-supervised learning for anomalous trajectory detection[C]. In: *Proceeding of British Machine Vision Conference*, 2008: 1035-1044.
- [53] Ellis D, Sommerlade E, Reid I. Modelling pedestrian trajectory patterns with gaussian processes[C], In: *Proceeding of IEEE 12th International Conference on Computer Vision Workshops*, 2009: 1229-1234.
- [54] Hermes C, Wiest J, Wöhler C, et al. Manifold-based motion prediction[J]. *Proc. 6. Dortmunder Auto-Tag. Dortmund, Germany*, 2011.
- [55] Keller C G, Hermes C, Gavrila D M. Will the pedestrian cross? Probabilistic path prediction based on learned motion features[M]. Pattern Recognition Springer Berlin Heidelberg, 2011: 386-395..
- [56] C. Li, Z. Han, Q. Ye, and J. Jiao, Visual abnormal behavior detection based on trajectory sparse reconstruction analysis[J]. *Neurocomputing*, 2013, 19: 94–100.
- [57] I. J. Schoenberg. Contribution to the problem of approximation of equidistant data by analytic functions[J]. *Quart. Appl. Math.*, 1946, 4(2): 45-99.
- [58] L. L. Schumaker, Spline Functions: Basic Theory [M]. New York: Wiley, 1981:112-130.
- [59] R. B. Fisher, J. Santos-Victor and J. Crowley, CAVIAR test case scenarios. URL <http://homepages.inf.ed.ac.uk/rbf/CAVIAR/>.
- [60] B.S. Kashin. Diameters of some finite-dimensional sets and classes of smooth functions[J]. *Izvestiya Rossiiskoi Akademii Nauk. Seriya Matematicheskaya*, 1977, 41(2): 334 - 351.
- [61] D. Donoho, and X. Huo, Uncertainty principles and ideal atomic decompositions[J]. *IEEE Transactions on Information Theory*, 2001, 47(7): 2845-2862.
- [62] S.G. Mallat, Z. Zhang. Matching pursuits with time-frequency dictionaries[J]. *IEEE Transactions on Signal Processing*, 1993, 41(12): 3397-3415.
- [63] J. Tropp, and A. Gilbert. Signal recovery from random measurements via orthogonal matching pursuit [J]. *IEEE Transactions on Information Theory*, 2008, 53(12): 4655-666.
- [64] M. Figueiredo, R. Nowak, and S. Wright, Gradient projection for sparse reconstruction: application to compressed sensing and other inverse problems[J]. *IEEE Journal of Selected Topics in Signal Processing*, 2007, 1(4): 586-597.
- [65] S. Chen, and D. Donoho, and M. Saunders, Atomic decomposition by basis pursuit[J]. *SIAM Journal on Scientific Computing*, 1998, 20(1): 33-61.
- [66] R. Tibshirani, Regression shrinkage and selection via the lasso[J]. *Journal of the Royal Statistical Society, Series B*, 1996: 267-288.
- [67] A.Y. Yang, J. Wright, Y. Ma, and S. S. Sastry, Robust face recognition via sparse

## 参考文献

---

representation[J]. *IEEE Transaction on Pattern Analysis and Machine Intelligence*, 2009, 31(2): 210-227.

[68] J. Yang, J. Wright, T. Huang, and Y. Ma, Image super-resolution as sparse representation of raw image patches[C]. *In: Proceeding of IEEE Conference on Computer Vision and Pattern Recognition*, 2008: 1-8.

[69] R. Toni M., M. R., Word image matching using dynamic time warping[C]. *In: Proceeding of IEEE Conference on Computer Vision and Pattern Recognition*, 2003: 521-527





## 个人简历及论文发表

### 个人简介

姓名：庞丽金 性别：女 出生日期：1988.06.06 籍贯：广西北流

◆ 2012.09-2015.07 中国科学院大学 工业工程 工程硕士

◆ 2008.09-2012.07 天津大学 电子信息科学与技术 学士

### 曾获荣誉：

2009年 天津大学电子信息工程学院“十佳歌手”

2009年 天津大学电子信息工程学院“优秀青年志愿者”

2010年 天津大学电子信息工程学院“暑期实践先进个人”

2011年 天津大学电子信息工程学院“三好学生”

### 已发表文章目录

- C. Li, Z. Han, S. Gao, L. Pang, Q. Ye, J. Jiao, "Locality-constrained Sparse Reconstruction for Trajectory Classification," in Proc. IEEE Int. Conf. Pattern Recognition(ICPR), 2014.
- 国家发明专利，“基于信息融合的行人快速检测跟踪技术”，申请号：201510071310.7（已受理）



## 致 谢

在中国科学院大学攻读硕士学位的三年学习生活中,经历了很多事情,在付出的同时,当然也收获了很多。藉此毕业论文完成之际,由衷的感谢这三年来给予我鼓励和帮助的老师、同学、朋友和家人。

首先,感谢焦建彬教授。这是一位慈祥可爱的好老师,在过去的三年时间里,焦老师不仅在科研问题上给我悉心的指导,生活中遇到任何问题也会热心帮我解决。作为一名孜孜不倦的学者,他严谨的治学态度和平易近人的学者风范使我感动,也深深的影响了我。

其次,感谢韩振军老师和叶齐祥老师。这两位老师非常耐心的指导了我的理论知识学习和科研工作,科研中的问题认真帮我指出讨论修正,他们渊博的学识、扎实的动手能力使我受益匪浅,感谢这两位老师在我生活上遇到困难的时候给我热心的帮助。

衷心的感谢实验室的师兄师姐们,特别是李策师姐、高山师兄、陈孝罡师兄,在我困难与迷茫的时候给我莫大的支持,科研上任何问题都会给我耐心的指导,由衷感谢三位。感谢崔妍婷、郑小梅,最脆弱的时候你们给我鼓励,谢谢你们两个陪我度过的三年美好的时光,因为有你们的陪伴,三年里无论是难过、开心还是面对困难,我一路坚定的走了下来,以后不管在哪里,你们都在我美好的回忆里。还要李兆举,很抱歉也很感谢,愿前程美好,一切顺利。

特别感谢我的父母和我的哥哥姐姐弟弟,感谢他们多年来养育我给我最无私的关怀和爱护,为我做了一切我都谨记在心,愿他们能够为我感到骄傲,祝我的父母健康长寿,希望我的兄弟姐妹生活开心美满。

感谢参加开题及中期评阅的各位老师和专家们,他们耐心的指出研究中存在的问题,并给出合理的建议帮助我把握论文方向和研究进度。

最后,感谢参加论文评审和答辩的各位老师。

庞丽金

2015年5月