密级:\_\_\_\_\_

# 中國科学院研究生院

# 硕士学位论文

基于轨迹分析的视觉目标异常行为检测算法研究

作者姓名:	李 策				
指导教师:					
	杨 辉 研究员 中国航空精密机械研究院				
学位类别:	工程硕士				
学科专业:	物流工程				
培养单位:	中国科学院研究生院工程教育学院				

2012 年 5月

# Visual Abnormal Behavior Detection Based on

### **Trajectory Sparse Reconstruction Analysis**

By Ce Li

#### A Paper Submitted to

**Graduate University of Chinese Academy of Sciences** 

In partial fulfillment of the requirement

For the degree of

**Master of Logistics Engineering** 

**College of Engineering** 

May, 2012

# 中国科学院研究生院直属院系 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:

# 中国科学院研究生院直属院系 研究生学位论文原创性声明

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:			导师	师签名:	
日	期:		日	期:	

#### 摘要

在智能交通物流领域中,一些涉及智能视频监控的应用需要解决视频智能 分析和异常行为识别等关键技术。视频运动目标行为分析在基于视频的安全监 控与视频内容分析检索等方面具有广泛的应用前景,也是计算机视觉领域中的 一个研究热点。轨迹分析基于图像处理、视频分析、模式识别与人工智能等相 关领域的研究成果,为运动目标的视觉行为分析提供了一个行之有效的方法。 本文以此为研究内容,具有理论意义和应用价值。

基于目标轨迹分析的异常行为检测的一般研究方法是通过学习样本的轨迹 模式,获取轨迹的分类模型,用于判断图像序列中的目标运动行为是否异常。 因此,运动目标轨迹表示和行为模式学习是异常行为检测的核心内容,也是本 文研究的重点。

本文提出了一种基于轨迹分析的视觉目标异常行为检测算法,该算法通过 稀疏重构分析构建运动行为的模式,进而检测和判断该场景中的异常行为。本 文的主要研究内容和贡献如下:

1、在目标轨迹表示的模块中,研究了基于 LCSCA(Least-squares Cubic Spline Curves Approximation,最小二乘三次 B 样条曲线逼近)的目标轨迹表示 算法,通过控制点对轨迹数据进行描述,一定程度上解决了目标轨迹描述长度 不一的问题。

2、基于 LCSCA 轨迹样本描述,提出了通过 SRA (Sparse Reconstruction Analysis,稀疏重构分析)轨迹行为模式学习的方法,从而实现特定场景中异常 行为的检测。其中,稀疏重构分析能够保证测试样本的重构系数会集中于尽可 能少的训练样本上,进而实现了轨迹模式的稀疏表示与重构。实验结果表明,本文所提的分类算法在训练样本较少的情况下仍然能取得较好的检测性能。

关键词:视频监控,目标轨迹表示,异常行为检测,最小二乘三次B样条的曲线逼近,稀疏重构分析

I

#### Abstract

• Ce Li (Logistics Engineering)

#### Directed by: Jian-bin Jiao (Professor)

In the field of intelligent transportation and logistics, some application involving intelligent video surveillance need to address the key technologies of intelligent video analysis and abnormal behavior recognition. Visual behavior analysis of moving object is one of the most important branches in the computer vision, and has a broad application field in video monitoring security system and video content analysis. The trajectory analysis, that combines advanced technologies and research achievements in image processing, video analytics, pattern recognition, artificial intelligence, and other relative fields, is a kind of effective method to visual behavior analysis of moving object. Therefore, this subject of this paper has important theoretical significance and wide practical value.

The general approaches of abnormal behavior detection based on motion trajectories are using the motion trajectories in the surveillance scene and finding the approach for classifier that distinguished between normal and abnormal behaviors. Therefore, motion trajectory representation and behavior patterns classification are key elements of such trajectory-based approaches for behavior detection, which are highly desirable to research in this paper.

In this paper, we propose a new method for abnormal behavior detection in surveillance videos based on the motion trajectories representation of objects and automatically behavior patterns learning. The main content and the contribution can be listed as following:

1) In the phase of motion trajectories representation, we adopt the method named LCSCA (Least-squares Cubic Spline Curves Approximation) as parametric vectors, which are constructed by the direction of motion and solve the problem of different length of motion trajectories to a certain extent.

2) On the basis of the LCSCA representation of trajectories, we proposed a method named sparse reconstruction analysis (SRA) of each trajectory behavior

II

patterns to detect abnormal behavior. The viewpoint is that sparse reconstruction analysis concentrates the sparse reconstruction coefficients on a little proportion of training samples. Experiment results show that the proposed approach is effective for detection, even when the training sample set is very small.

KEY WORDS : Visual Surveillance, Motion Trajectory Representation, Abnormal Behavior Detection, LCSCA, Sparse Reconstruction Analysis

摘 要	I
Abstract	II
目 录	IV
图目录	VI
表目录	VII
<b>第一章</b> 绪论	1
1.1 课题背景和研究意义	1
1.2 国内外研究现状	2
1.3 异常行为检测的主要研究内容和分类	4
<b>1.3.1</b> 异常行为检测的研究内容	4
<b>1.3.2</b> 异常行为检测的研究分类	4
<b>1.3.3</b> 异常行为检测的发展趋势	5
<b>1.4</b> 本文的研究内容	5
<b>1.5</b> 本文的组织结构	7
第二章 基于轨迹分析的视觉目标异常行为检测的研究基础	9
2.1 引言	9
2.2 目标轨迹表示	9
2.3 异常轨迹检测	
2.4 基于轨迹分析的视觉目标异常行为检测研究算法简介	
2.5 监控视频中目标轨迹获取简介	19
2.6 本章小结	
第三章 基于 LCSCA 的目标轨迹表示算法	
3.1 LCSCA 的基本理论	
<b>3.1.1</b> LCSCA 的提出	
<b>3.1.2</b> LCSCA的基本理论	
3.2 基于 LCSCA 的目标轨迹表示算法	
3.3 基于 LCSCA 的目标轨迹表示的实验	
<b>3.3.1</b> 实验步骤	
3.3.2 测试集合及算法评估	
<b>3.3.3</b> 实验结果及分析	
3.4 本章小结	
第四章 基于稀疏重构分析的异常行为检测算法	

4.1 稀疏重构分析的基本理论	33
<b>4.1.1</b> 稀疏重构分析综述	33
<b>4.1.2</b> 1-范数研究综述	33
<b>4.1.3</b> 稀疏重构的基本原理	34
4.1.4 稀疏重构在图像/视频处理领域的应用	
4.2 基于稀疏重构分析的异常行为检测算法	
<b>4.2.1</b> 目标轨迹的样本集构造	
4.2.2 目标轨迹的稀疏重构分析	39
4.2.3 基于稀疏重构分析的异常行为检测	41
4.3 基于稀疏重构分析的异常行为检测实验	42
4.3.1 实验步骤	42
<b>4.3.2</b> 测试集合及算法评估	43
<b>4.3.3</b> 实验结果及分析	44
<b>4.4</b> 本章小结	47
总结与展望	49
参考文献	51
作者简历及论文发表	59
附录:主要符号对照表	60
致 谢	61

# 图目录

图	1-1	智能视频监控工作过程示意图	1
图	1-2	异常行为检测的框图	5
冬	3-1	B 样条基函数的递归定义示意图	22
图	3-2	一般 B 样条曲线的凸包性示意图	24
图	3-3	三次 B 样条曲线中基函数示意图	25
图	3-4	<i>p</i> =7 时,LCSCA 轨迹表示的示意图	27
图	3-5	基于 B 样条曲线拟合误差的控制点数的选择示意图	31
图	4-1	稀疏重构模型	34
图	4-2	CAVIAR 中不同运动目标的轨迹示意图	38
图	4-3	轨迹实例和相应 LCSCA 表示示意图	39
图	4-4	目标轨迹稀疏重构分析实例	41
图	4-5	R1 表示时 DACC 和 CCR 结果	44
图	4-6	R2 表示时 DACC 和 CCR 结果	45
冬	4-7	两种方法对比的 ROC 曲线	46

# 表目录

表	2-1 基于轨迹的异常行为检测研究的方法对比1	19
表	3-1 基于 B 样条曲线拟合误差的控制点数的选择算法	30
表	4-1 基于稀疏重构分析的异常行为检测算法	42

#### 第一章 绪论

#### 1.1 课题背景和研究意义

随着智能交通物流的普及,一些支持智能交通管理、交通信息服务与运营、 物品仓储运输的监测与预警的应用涉及到智能视频监控,需要解决视觉传感智 能分析、视频数据处理、目标检测与异常行为识别等关键技术。目前,监控摄 像机在人们日常生活中一些安全敏感的场合已经非常普及,像机场、银行、交 通路口、商场出入口等。但这些监控摄像机往往有着智能化程度低,需要派专 人查看来区分监控场景中正常的运动行为和异常的运动行为,这不仅会浪费大 量的人力资源,还容易产生疏忽和纰漏。

因此,智能视频监控作为一种直观、有效、智能化程度高的安防新手段, 正越来越多的受到人们的青睐。一般的智能视频监控工作过程如下图 1-1 所示, 其通过实时的场景视频数据采集,自动地提取运动目标的特征,自动地描述和 分析目标的行为,这不仅能高效地完成保障安全的任务,还能节省人力物力, 给社会带来很大的经济收益。

一个完整的智能监控系统,其研究内容涉及到运动目标检测、目标分类、 目标跟踪和异常行为分析四大问题。其中,检测、分类、跟踪三个问题目前研 究较多,而异常行为的理解和分析近年来才被广泛关注。由于视频监控系统的 最终目的往往是为了解释监控场景中的目标行为,根据要求对序列图像中的运 动异常进行检测,因此视频序列中目标异常行为的分析在智能视频监控领域中 也日益受到重视。



图 1-1 智能视频监控工作过程示意图

但是,现有的视觉监控系统中的异常行为检测模块主要依赖于已知场景以 及在这些场景中目标预先定义的运动模式,这种方法过于依赖操作人员的主观 性,对环境的适应性不强。然而实际应用中,特定场景中大量的目标运动轨迹 可以反映出该场景中的目标运动的行为模式,监控系统中可以通过目标跟踪获 得三维时变序列(包含位置和时间信息)的轨迹数据,这种基于目标轨迹分析 的研究与以往不同,能够针对不同的场景构造出有效的目标运动行为模式,具 有一定的通用性和适应性,是运动目标行为分析领域的一个行之有效的方法, 具有广泛的应用前景和广阔发展空间。

针对目标轨迹分析的异常行为检测的关键问题是根据学习样本的轨迹数 据,来获取参考的分类模型用于判断图像序列中的目标运动行为是否异常。然 而,模型的建立受到监控场景的多样性、目标运动方向的不确定性、目标运动 轨迹的长度差异性等影响,存在一些需要解决的问题,如不同长度轨迹聚类计 算量大、目标运动的整体方向区分较弱、参考的行为序列模型对目标运动的轻 微特征变化不够鲁棒等。此外,采用监控视频中运动目标的轨迹表示来分析运 动行为,需要较为准确的目标检测和跟踪结果,因而运动目标行为分析领域的 研究不仅可以推动计算机视觉、模式识别、人工智能等相关领域的整体研究, 而且可以将其研究成果与其它研究方向(如目标检测、目标跟踪、机器学习) 相互借鉴。

在论文工作期间,本文作者参与并受到以下课题资助:

 "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);

3) "复杂环境下动态目标跟踪技术"中科院"百人计划"择优支持项目(项目编号: 99T3009EA2)。

#### 1.2 国内外研究现状

通过对国内外行为分析研究现状的调查可以发现,由于智能视频监控系统 在民用、商业、国防安全和军事应用领域中有着很大的需求,各国研究人员对

此高度重视,投入了大量资金进行广泛研究。当前,针对这一领域的最新理论研究,许多重要的国际学术会议和权威期刊也进行了专门讨论,如: CVPR (Computer Vision and Pattern Recognition)、ICCV (International Conference on Computer Vision)、ECCV (European Conference on Computer Vision)、 ACCV (Asian Conference on Computer Vision)、 ICPR (International Conference on Pattern Recognition)、IJCV (International Journal of Computer Vision)、 PAMI (IEEE Transaction on Pattern Analysis and Machine Intelligence)、IVC (Image and Vision Computing)、IWVS (IEEE International Workshop on Visual Surveillance)、 IEEE Transaction on Image Processing、Pattern Recognition 等将运动目标的行为 分析研究作为主题内容之一,为该领域的研究人员提供了更多的交流机会。

国外在这方面的研究起步较早,很多著名的视频监控原型系统中都包括了 场景中运动目标的行为分析研究。例如,美国国防高级研究项目署资助的 HID 研究能够快速从监控视频中发现并分析人的活动;Maryland 大学的实时监控系 统 W4<sup>[1]</sup>能够对进出民宅、停车场、银行等场合的可疑人员的简单行为进行有效 的实时监控;欧洲的 AVS-PV (Advanced Video-based Surveillance Prevention of Vandalism in metro stations)项目<sup>[2]</sup>实现对地铁站内人的活动行为进行监控;英 国雷丁大学的 VIEWS 项目组<sup>[3]</sup>已开展了对车辆和行人的跟踪及其交互作用识 别的相关研究,这一新技术主要通过分析不同物体(如汽车、人)的运动轨迹 来分析反常行为并快速发出警报。

随着图像处理技术和图像传感器技术的飞速发展,智能化监控技术在中国的推广得到国家的高度重视,公安部为此在全国开展城市报警与监控系统建设 "3111"试点工程,863项目为此开展了重大项目研究,促使国内的一些研究 团队逐渐开展视频监控中行为分析的研究。如:中国科学院自动化所模式识别 国家重点实验室图像和视频分析研究组<sup>[4]</sup>开发的人体运动视觉分析系统、交通 行为事件分析系统、交通场景监控系统、和智能轮椅视觉导航系统是这方面研 究成果的集中展示;清华大学智能技术与系统国家重点实验室智能视觉研究组 <sup>[5][6]</sup>在视觉监控应用研究上卓有成效,主要有基于视频的十字路口交通流分析、 高速公路出口的车辆行为监控、广场等公众聚集场所的"天视"数字监控解决 方案等多项国家重点项目;西安交通大学将运动背景下的车辆行为分析用于自

适应巡航控制的车载系统中;北京航空航天大学电子信息工程学院在航空交通 领域针对精确定位航迹的监控、航管综合监控的关键理论和技术问题展开了研 究;北京工业大学信号与信息处理研究室主要研究智能视频监控中的场景检测 分析需要涉及的异常检测、异常分析等关键技术。

#### 1.3 异常行为检测的主要研究内容和分类

#### 1.3.1 异常行为检测的研究内容

由于人们往往把监控视频中针对目标轨迹的分析作为行为分析和理解的基础,所以,基于运动目标轨迹分析的异常行为检测就可以简单地理解成对时变数据的表示和分类问题,即将测试序列与预先标定的能代表场景中典型行为的参考序列进行匹配分类,进而检测判断出异常行为。由此可见,基于目标轨迹分析的异常行为检测研究的基本框架中包含了以下两个关键问题:1)轨迹表示问题,即如何将时变数据表示为学习序列;2)异常行为检测问题,即如何学习轨迹的分布模式用来检测异常行为的轨迹。

#### 1.3.2 异常行为检测的研究分类

以上两个问题,国内外研究人员经过多年努力,已形成了一些比较实用、 有效的方法<sup>[7-14]</sup>。这些方法按照不同的标准可以有不同的分类,经过我们的调 研和总结,异常行为检测研究的分类有:

1) 按照轨迹表示的方法不同, 异常行为检测的研究可以分为两大类: 基于 轨迹分量的目标轨迹研究方法和基于曲线逼近的目标轨迹研究方法。由于目标 轨迹的异常行为分析关注的不仅仅是轨迹数据的分量, 更多的是目标轨迹的形 状、方向等信息, 因而近几年这方面的研究侧重于基于目标轨迹的曲线逼近的 表示方法。本文所用的目标轨迹表示方法就属于基于曲线逼近的目标轨迹研究 方法。

2) 按照异常行为检测中的模式学习的方法不同,视频监控中的异常行为检测可以分为以下三类:有监督的行为学习方法<sup>[15]</sup>、无监督的行为学习方法<sup>[15]</sup>和半监督的行为学习<sup>[16][17]</sup>方法。这三类学习方法中,通常无监督的行为学习方法多数都需要预先定义聚类的数目。本文提出的目标轨迹稀疏重构分析方法属

于有监督的行为学习方法。

#### 1.3.3 异常行为检测的发展趋势

以上介绍可以看出,目标运动轨迹分析和异常行为检测研究已经受到广大 研究人员的高度重视。现有的异常行为检测方法,在一定程度上完成了异常检 测。但是,在目标轨迹表示方面,存在目标运动轨迹表示是否为固定长度、表 示序列的长度是否能够方便地根据模式分析的需要来选择等问题需要改进,在 模式学习方面,复杂多变的行为类内方差往往很大,如何提高学习得到的分类 模型的精确性、鲁棒性,如何将时变序列模式识别方法有效地应用到异常行为 检测中,这一系列的问题值得我们在未来的工作中加以改进。针对这几个问题 的研究,将会减少轨迹表示序列中的冗余信息,获取目标轨迹的有效表示,有 利于构建鲁棒的分类模型,提升异常行为的检测效果。



#### 1.4 本文的研究内容

图 1-2 异常行为检测的框图

为了开发一种鲁棒的异常行为检测算法,解决运动目标轨迹表示包含形状、 方向信息、表示序列长度问题,构建鲁棒的分类模型,本文主要提出了基于目 标轨迹分析的异常行为检测算法,该算法根据学习样本的轨迹数据,来获取参 考的分类模型用于判断图像序列中的目标运动行为是否异常。在目标轨迹长度 不一、运动目标的运动方向多样等情况下,该算法仍然具有较好的鲁棒性,并 且该方法对于特定场景中小的训练样本集也很有效。本文重点针对上一节提出 的基于目标轨迹分析的异常行为检测研究的基本框架中包含的关键问题提出目 标轨迹表示和异常行为检测两个模块,着重研究以下两个具体算法:基于 LCSCA 的目标轨迹表示算法、基于稀疏重构分析的异常行为检测算法。本文异 常行为检测的研究框图如图 1-2 所示。

基于 LCSCA 的目标轨迹表示算法: LCSCA 曲线逼近方法通过对目标轨迹 的三维时变序列数据的变换求解,为解析各种曲线表示提供了一个公共的数学 表示,尤其是控制顶点和权值因子为精确表示和解析各种形状的曲线提供了充 分灵活性。该方法的实质是以距离加权插值法为基础,以数据点为型值点来反 求其控制点的过程。算法中,首先根据目标轨迹的分布趋势,构造参数矢量和 非均匀节点矢量。接着使用计算得到的节点矢量构造出非均匀的 B 样条基,构 建反求控制点的系数矩阵,最后建立了控制点反算方程,求解出控制点序列用 作目标轨迹的表示。这种固定长度的表示序列包含了运动目标的运动方向信息, 解决了目标轨迹长度不一的问题。由于该算法中给出了控制点个数这一可供优 化选择的参数,从而保证了选取对原始轨迹数据的最好拟合情况,通过实验验 证了该目标轨迹表示方法的有效性。

基于稀疏重构分析的异常行为检测算法:将监控场景中异常行为检测理解 为测试样本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进而 检测判断的过程。由于监控场景中的行为模式(样本集构造的模式)往往很多, 导致使用样本集进行新样本重构的系数会很稀疏,样本集中的多数类别的样本 对应重构系数趋近于零,因此在本文中提出了基于稀疏重构分析获取样本稀疏 重构系数和重构误差的方法。这种方法在获得样本集的基础上,对样本集中的 所有样本通过重构系数和重构误差进行评估,从而选择出最具有代表性的一些 样本来重构新样本。这些样本揭示着新样本轨迹的主要特征和内在结构,通过 对新样本的重构,从而使得异常行为检测具有较强的鲁棒性。本文通过算法的 检测结果实验验证了算法的有效性。

#### 1.5 本文的组织结构

第一章,绪论。主要论述了异常行为检测算法的研究背景和意义,分析了 国内外的行为分析的研究现状以及异常行为检测算法的发展趋势,列出了本文 的主要研究目的和研究内容。

第二章,基于目标轨迹分析的异常行为检测的研究基础。主要综述了目标 轨迹表示算法和异常行为轨迹检测的主要研究内容和方法,同时也对基于稀疏 重构分析的异常行为检测算法的基本思想进行简单介绍。

第三章, 基于 LCSCA 的目标轨迹表示算法。主要论述了 LCSCA 基本知识 和用于目标轨迹表示的原理方法,详细介绍了 LCSCA 的目标轨迹表示算法。 最后,给出了该算法在同一数据集上不同参数选择的表示对比实验,从而对该 算法采用不同参数值对原始轨迹数据的拟合情况进行了比较,并对比较结果进 行了分析。

第四章,基于稀疏重构分析的异常行为检测算法。主要论述了稀疏重构分 析在处理信号、图像等领域的稀疏优势,以及求解方法。详细介绍了基于稀疏 重构分析获取新样本的重构系数,从而检测异常行为的方法。最后,给出了该 算法的检测结果实验,从而对算法在目标轨迹长度不一、运动目标的运动方向 多样等情况下的鲁棒性进行了验证,同时将该方法对于特定场景中小的训练样 本集的有效性与其他异常行为检测算法进行了比较和分析。

最后是结束语,总结了本文的主要工作,展望了未来工作的方向,以及对 如何进一步提高跟踪算法的鲁棒性、准确性等研究热点和难点的探讨。

#### 第二章 基于轨迹分析的视觉目标异常行为检测的研究基础

异常行为检测是计算机视觉领域的热点研究问题之一。目前,针对如何提高异常行为检测算法的鲁棒性和准确性等方面的研究逐步成为行为分析研究的重点。本章将主要介绍目标轨迹表示和异常轨迹检测的一些传统方法,并对基于稀疏重构分析的异常行为检测算法的基本思想进行简单介绍。在接下来的第三章和第四章,本文将详细介绍基于 LCSCA 的目标轨迹表示算法和基于稀疏

#### 2.1 引言

对于一个特定的场景,我们希望计算机能够通过观察场景中目标的运动行 为,自动得出目标在该场景中的运动模式判断。由于,大多数监控场景中的行 为模式(样本集构造的模式)往往种类很多,不是简单单一的,所以它们的行 为模式都不可能直接用一种模型训练得出。针对这种情况,本文把基于轨迹的 异常行为检测分为两步,首先是目标轨迹表示,把目标轨迹的三维时变序列数 据的变换为表示序列,然后进行样本集的构建,给新样本的运动行为分类,即 将测试序列(新样本)与预先标定的代表典型行为的参考序列(学习的样本集 合)进行匹配。由此可见,用于检测异常的学习方法需要能够处理在相似的行 为模式类别时空间和时间尺度上轻微的特征变化,即该方法要具有一定的鲁棒 性。

#### 2.2 目标轨迹表示

自上世纪 90 年代以来,经过二十多年的发展,基于轨迹的异常行为检测得 到了充分的发展,提出的算法越来越多。根据目标轨迹表示的方法不同,异常 行为检测的研究可以概括为两大类:基于轨迹分量的目标轨迹研究方法和基于 曲线逼近的目标轨迹研究方法。 ■ 基于轨迹分量的目标轨迹研究方法:

这一类方法将目标轨迹的分量(位置、速度、加速度等信息)作为表示序 列,是轨迹表示和分析研究中的较为直接的一类方法。Johnson等<sup>[18]</sup>在1996年 最早开始研究基于轨迹的异常行为检测,将跟踪得到的目标运动轨迹描述成连 续的流矢量(包含轨迹的目标位置和速度分量信息),学习出由两个连接着弱神 经元的竞争学习神经网络组成的概率密度模型用于检测,其中行为模式的数目 需要预先设定,并且各个输入样本的表示序列对模式调整只提供一次贡献,没 有反复迭代学习。Owens等<sup>[14]</sup>在2000年对以上目标轨迹的流矢量表示加以改 进,引入加速度信息,提出了通过使用SOM(自组织映射)神经网络来学习流 矢量的分布,该方法只能决定轨迹中的一个点是否异常并不能识别轨迹所代表 的运动行为。Stauffer等<sup>[19]</sup>通过将流矢量用在线 K-均值聚类的方法构造多条目 标跟踪的轨迹的联合共生统计量表,并以此来进行轨迹分类。

为了解决以上方法中目标轨迹的表示序列长度不一致的问题,Hu 等<sup>[20-22]</sup> 提出在流矢量中加入轨迹长度信息,采用等距离间隔采样来线性插值逼近获得 固定长度的表示序列用于模糊 K-均值聚类学习运动模式,并通过计算运动模式 的最大后验概率阈值来检测异常行为。

上述方法都是针对一次获得全部训练样本的轨迹数据研究,而 2006 年 Piciarelli和 Foresti<sup>[23]</sup>提出在线聚类算法则是针对逐次获得的训练样本。文中对 逐个获得的训练轨迹计算与聚类原型间归一化的欧式距离的平均值,以此为依 据更新树状聚类结构上的节点(包括添加和分裂操作),并使用累计频率信息来 判断目标行为是否异常。Piciarelli等<sup>[24]</sup>后来又对重采样的固定长度的轨迹矢量 使用 One-class SVM (一类支持向量机)分类方法来训练模型,达到检测异常 行为的目的。然而,但文献中并未对如何选择适当的重采样多做出解释。在此 之后,Dizan等<sup>[25]</sup>提出了基于 GHMM (Growing Hidden Markov Model,增长的 隐马尔科夫模型)的增量学习重采样的目标运动轨迹矢量的算法,该方法随着 观察序列的到达,每次都要更新离散状态数目、状态矩阵和概率参数。

■ 基于曲线逼近的目标轨迹研究方法:

目标轨迹的异常行为分析关注的不仅仅是轨迹数据的分量,更多的是目标 轨迹的形状、方向等信息,因而近几年这方面的研究产生了另一类基于目标轨

迹的曲线逼近的表示方法。Naftel 等<sup>[26]</sup>2006 年首次将曲线逼近的方法用于轨迹 表示,分别使用最小二乘多项式、Cheybyshev 多项式、DFT(Discrete Fourier Transform,离散傅里叶变换)三种方法计算轨迹曲线的系数特征矢量,并按照 系数特征矢量间的欧氏距离聚类分析。在此基础上,Rowland等文献<sup>[27]</sup>中对 Haar 小波变换、离散傅里叶变换、Cheybyshev 多项式函数逼近的系数特征矢量表示 和三次 B 样条控制点特征矢量表示在五个不同目标轨迹数据集上作了对比,三 次 B 样条控制点的轨迹表示方法在对比实验定义的评价指标中表现较好。而且, Rowland 等<sup>[26][27]</sup>还将三次 B 样条控制点的轨迹表示方法用在了其提出的 SI-GMMs(Semisupervised Incremental Gauss Mixture Models 半监督的增量高斯 混合模型)学习框架中,取得了检测异常行为轨迹的较好实验结果。

基于函数逼近的目标轨迹曲线表示方法实质就是把轨迹数据通过某种变换 求得表示矩阵的方法,即由 $T = \{(x_1, y_1), (x_2, y_2), \cdots, v_{N-1}\}, (x_N, y_N)\}$ 表示为  $F = \{C_1^x, C_2^x, \cdots, \dots, \dots, v_N\}$ 。以下是三种典型求解方法的介绍。

1) Haar 小波系数法。该方法基于 Haar 小波变换的尺度函数和小波函数, 将参数向量和轨迹序列 *T* 通过该算法中求得 Haar 小波系数,作为表示序列 *F*。 该算法要求轨迹上的轨迹点数为 2 的整数次幂,否则需要通过线性插值来达到 这一条件。

2) DFT 变换法。离散傅里叶变换通常就是将一堆数据变成其他表示空间中的另一堆数据。DFT 的轨迹表示法就是利用每种傅里叶变换的结果中的实部和虚部值来构造表示序列 F。

3) Cheybyshev 多项式系数法。由于切比雪夫节点(第一类切比雪夫多项式 的根)可以用于多项式插值,所以切比雪夫多项式系数可以提供多项式在连续 函数的最佳一致逼近。该方法通过求解切比雪夫多项式函数的系数作为表示序 列*F*。然而,由于切比雪夫多项式是定义在对偶区间[-1,1]上的正交化多项式, 该算法具有一定的局限性,要求计算的参数向量的定义域必须变换到对偶的闭 区间上。

近年来,基于曲线逼近的目标轨迹研究方法相对于基于轨迹分量的目标轨 迹研究方法,因为具有以下优势而受到研究人员的青睐。首先,该类方法更多

地关注轨迹曲线的趋势信息,得到的表示序列包含了目标轨迹的形状、方向等, 这种表示对由于视频监控中遮挡原因所产生的目标跟踪结果中不完整的噪声轨 迹具有鲁棒性。其次,基于曲线逼近的一些目标轨迹表示方法可以得到固定长 度的表示序列,使得这种目标行为模式的轨迹表示方法很容易和其他模式分析 的方法结合使用。本文所用的基于 LCSCA 的目标轨迹表示就属于基于曲线逼 近的目标轨迹研究方法。

#### 2.3 异常轨迹检测

对于异常轨迹检测的研究越来越多的集中于算法的鲁棒性上。经过这些年 的发展,异常轨迹检测中的模式学习方法主要有三类: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:

有监督的模式学习方法是在预先确定行为模式的模型的情况下,通过训练 和学习得到对样本集合的模式模型。这类方法在检测过程中利用得到的模型, 可以较快地得到新样本的学习结果,而且适用于对简单的轨迹模式学习。但是, 这类方法一般对模型的合适要求很高,当训练模型出现"欠拟合"和"过拟合" 时,往往很可能在训练集以外的数据集上得不到有效的结果。它一般包括以下 几种算法:

1) FSM (Finite State Machine,有限状态机)。FSM 是一种根据多种模型提供的检测结果来存储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的结构<sup>[28]</sup>。它由有限数目的状态和状态之间的相互转移构成,得到一个状态转移函数,用于确定最佳状态,并用该状态确定测试样本和参考样本是否匹配。FSM 可以分成确定有限态自动机与非确定有限态自动机, 二者区别就在于转移函数的不同。对每一个可能的输入,确定有限态自动机只有一个状态转移,而非确定有限态自动机可以有多个状态转移,需要确定最佳状态时随机非确定地选择其中之一。刘<sup>[28]</sup>在轨迹分析中应用了有限状态机,实现了辅助驾驶中危险事件的检测。

2) HMM (Hidden Markov Model, 隐马尔科夫模型)。HMM 是马尔科夫链的一种,它的状态不能直接观察到,但能通过观测向量序列观察到,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。HMM 的使用涉及到 训练和分类两个阶段<sup>[15]</sup>,训练阶段包括制定一个隐马尔科夫模型的隐藏的状态 数,并且优化相应的状态转换和输出概率以便输出与在特定的运动类别内所观 察到的特征相匹配。分类阶段需要计算一个特定的 HMM 可能产生相应于所观 察的目标轨迹序列的概率。近年来,HMM 已成功地应用到行为识别领域。Oliver 等<sup>[29]</sup>提出并比较了两个不同的基于状态的人的行为建模学习方法:HMM 和 CHMM (Coupled Hidden Markov Model)。后来,为了学习变长时间量度的行 为轨迹,Dizan 等<sup>[25]</sup>提出了基于 GHMM (Growing Hidden Markov Model,增长 的隐马尔科夫)模型的增量学习重采样的目标运动轨迹矢量的算法,该方法随 着观察序列的到达,每次都要更新离散状态数目、状态矩阵和概率参数。

3) One-Class SVM。SVM 方法是近年来热门的机器学习算法,因为它较好 的数据处理效果及对样本的宽松要求,广泛的应用于行为分析和识别中。其中, One-Class SVM 方法于 2001 年由 Scholkopf 等<sup>[30]</sup>在 SVM 的基础上提出,但是 它与 SVM 有很大的不同,主要体现在:其不要求大量的正例反例样本,且主 要应用只包含一类样本信息中。One-Class SVM 的基本思想是假设某一类样本 数据在特征空间中具有一定的概率分布,通过构建描述样本概率分布的二值模 型,判断待测试的样本在特征空间是否服从该模型分布,即该待测数据属于该 类或不属于该类。实际中,One-Class SVM 是在特征空间中估计一块体积最小 的部分,需要包含尽可能多的相关样本,同时保持较大的分类间隔<sup>[31]</sup>。因此, 它可以被应用到异常轨迹检测中,Piciarelli 等<sup>[24]</sup>就利用对重采样的固定长度的 轨迹矢量使用 One-class SVM 分类方法来训练模型,达到检测异常行为的目的, 并取得了较好的结果。

上述方法都是模式识别领域中目标识别的经典方法,近些年来陆续被引入 到行为分析和异常轨迹检测中加以应用。其中,FSM 中预先定义的状态十分有 限,适合监控场景中的较简单的模式学习。HMM 的训练方法要求大量的轨迹 点,否则将出现过拟合的现象。One-Class SVM 通常需要大量的训练数据,而 监控场景中异常行为轨迹的数据搜集相对比较困难,往往很难达到训练的要求。 此外,神经网络学习速度较慢的缺点也无法克服。

■ 无监督的学习方法:

无监督的学习方法是指直接对训练样本进行学习,自动得到目标的运动行 为模式。在大多数应用中,目标的运动模式只能通过对监控场景中的连续序列 进行自动地学习,因此,这类方法比有监督的学习方法更为适用,这方面的研 究典型的有 SOM 神经网络和一些轨迹聚类分析方法<sup>[19,33-36]</sup>。

SOM 神经网络<sup>[32]</sup>是一种无导师神经网路。网络的拓扑结构是由一个输入 层与一个输出层构成。输入层的节点数即为输入样本的维数,其中每一节点代 表输入样本中的一个分量。输出层节点排列结构是二维阵列。输入层 X 中的每 个节点均与输出层 Y 每个神经元节点通过一个权值(权矢量为 W)相连接,这样 每个输出层节点均对应于一个连接权矢量。 自组织特征映射的基本原理是, 当 某类模式输入时,其输出层某一节点得到最大刺激而获胜,获胜节点周围的一 些节点因侧向作用也受到较大刺激。这时网络进行一次学习操作,获胜节点及 其周围节点的连接权矢量向输入模式的方向作相应的修正。当输入模式类别发 生变化时,二维平面上的获胜节点也从原来节点转移到其它节点。这样,网络 通过自组织方式用大量训练样本数据来调整网络的连接权值,最后使得网络输 出层特征图能够反映样本数据的分布情况。根据 SOM 网络的输出状况,不仅 能判断输入模式所属的类别,使输出节点代表某类模式,而且能够得到整个数 据区域的分布情况,即从样本数据得到所有数据的分布特征。Owens 等<sup>[14]</sup>在 2000 年在目标轨迹的流矢量中引入加速度信息,提出了通过使用 SOM 神经网 络来学习流矢量的分布,然而,该方法只能决定轨迹中的一个点是否异常并不 能识别整条轨迹所代表的运动行为。

轨迹聚类的方法是基于轨迹相似性的度量距离,将距离相近的轨迹归为一 类。例如,Stauffer等<sup>[19]</sup>通过将流矢量用在线 K-均值聚类的方法构造多条目标 跟踪的轨迹的联合共生统计量表来进行轨迹分类。Liu 等<sup>[33]</sup>提出了基于马氏距 离的模糊 C-均值轨迹聚类方法。郝等<sup>[36]</sup>提出利用轨迹的空间特征和速度方向特 征改进轨迹相似性度量方法计算轨迹间距离,随后采用层次聚类算法对同一场 景区域内的轨迹聚类分析。

这些轨迹聚类方法中重要的是对轨迹相似性度量方法的定义,就是轨迹聚 类首先需要一种衡量轨迹样本相似度的方法。对此,Hu的实验室曾对经典的轨 迹聚类中的不同轨迹相似性度量方法作了深入研究,Zhang<sup>[21][22]</sup>的对比实验结

果说明,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。传 统的 Euclidean 距离要求两条轨迹的轨迹点个数相同,PCA+Euclidean 距离的方 法丢失了轨迹点的运动方向信息,Hausdorff 距离可以对不同长度的轨迹进行编 码,但没有考虑轨迹方向而且时间消耗较高,LCSS 和 DTW 方法能有效地度量 轨迹,但从理论上分析更适于描述柔性物体的形状变换轨迹。文献<sup>[21]</sup>中权衡了 识别率和时间消耗,认为 PCA+Euclidean 距离表现较好,更适于监控视频中的 目标轨迹聚类。

以下是这几种轨迹距离度量的定义介绍<sup>[21]</sup>。一般地,一条目标轨迹被表示为二维空间的坐标序列,如{ $(a_1^x, a_1^y), (a_2^x, a_2^y), \cdots$  }},假设A和B分别是长度为N和M的轨迹。

1) Euclidean 距离。传统的 Euclidean 距离要求两条轨迹的长度相等,即 *N=M。A*和 *B*之间的 Euclidean 距离为相应坐标向量的平方差之和的开方,公 式如下所示:

$$D_{1}(A,B) = \frac{1}{N} \sum_{n=1}^{N} \left[ (a_{n}^{x} - b_{n}^{x})^{2} + (a_{n}^{y} - b_{n}^{y})^{2} \right]^{\frac{1}{2}}$$
(2-1)

2) PCA+Euclidean 距离。首先,轨迹的原始序列的 x-y 坐标值被投影成一维向量,于是轨迹原始序列转换为一些 PCA 系数,如  $\{a_1^c, a_2^c, \cdots \}$ 。求解 A 和 B 之间的 PCA+Euclidean 距离定义为计算 PCA 系数的 Euclidean 距离,公式如下所示:

$$D_2(A,B) = \left[\sum_{k=1}^{K} (a_k^c - b_k^c)^2\right]^{\frac{1}{2}}$$
(2-2)

其中, *a<sup>c</sup>*<sub>*k*</sub> 和 *b<sup>c</sup>*<sub>*k*</sub> 分别表示 *A* 和 *B* 的第 *k* 个 PCA 系数, 且 K<<2*N*, *N* 的定义同上,表示 *A* 和 *B* 的轨迹的长度。

3) Hausdorff 距离。Hausdorff 距离是有限像素点集合之间的一种距离,度量的是两个特征点集之间的相似度。已知两组有限像素点集合 $A = \{a_1, a_2, \cdots$ 和 $B = \{b_1, b_2, \cdots$ ,则 Hausdorff 距离定义如下:

$$D_{3}(A,B) = \max\{d(A,B), d(B,A)\}$$
(2-3)

其中,  $d(AB \Rightarrow a_{a_i \in A} a_{b_j \in B} a_{a_i} - b_j \| i$ , 是点集  $A = \{a_1, a_2, \cdots$  到点集  $B = \{b_1, b_2, \cdots$  的有向 Hausdorff 距离, 表示点集 A 中所有点到点集 B 的距离  $d_B(a_i)$  的最大值。定义 $d_B(a_i) = \min_{b_j \in B} \|a_i - b_j\|$ , 表示点 $a_i$  到集合 B 的距离, 是点 $a_i$ 到集合 B 中每一点距离的最小值。这里  $\| a_i - b_j \|$ , 表示某种范式, 根据使用特征的不同, Hausdorff 距离可以选择使用不同的范式形式, 轨迹特征的 Hausdorff 距离主要 使用均方误差函数、绝对差累加和函数、归一化互相关函数等。

4) LCSS 距离。最长公共子序列距离是基于最长公共子序列的概念提出的。 最长公共子序列可以用来描述两段序列之间的相似度,它的定义是,一个序列, 如果分别是两个已知序列的子序列,而且是所有符合此条件序列中最长的,则 其成为己知序列的最长公共子序列。假定 *Head(A)*是 *A* 的前 *N*-1 个轨迹点, *Head(B)*是 *B* 的前 *M*-1 个轨迹点, δ 和 ε 是较小的阈值,那么 *LCSS(A,B)*最长公 共子序列的长度为:

 $\begin{cases} 0 & \text{if } A \text{ or } B \text{ is empty} \\ 1 + LCSS_{\delta,\varepsilon}(Head(A), Head(B)) & \text{if } \|a_N - b_M\| < \varepsilon \text{ and } |N - M| \le \delta \quad (2-4) \\ \max(LCSS_{\delta,\varepsilon}(Head(A), B), LCSS_{\delta,\varepsilon}(A, Head(B))) & \text{others} \end{cases}$ 

在此基础上, A和B的最长公共子序列距离定义如下:

$$D_4(\delta,\varepsilon,A,B) = 1 - \frac{LCSS_{\delta,\varepsilon}(A,B)}{\max(N,M)}$$
(2-5)

其中,  $||a_N - b_M||$ 是点集 A 中第 N 个点与点集 B 中第 M 个点的某种范式。在 R<sup>n</sup>

上向量  $x = (x_1, x_2, ... \quad R^n$  有三种常用的范数形式, 1-范数:  $\|x\|_1 = \sum_{i=1}^n |x_i|$ ; 2-

范数:  $\|\mathbf{x}\|_2 = \left(\sum_{i=1}^n x_i^2\right)^{\frac{1}{2}}; \quad \infty - 范数: \quad \|\mathbf{x}\|_{\infty} = \max_{1 \le i \le n} |x_i|.$ 

5)DTW距离。与LCSS类似,DTW距离也是基于序列对齐的距离。DTW 算法是基于动态规划的思想提出的把时间规整和距离测度计算结合起来,把测 试序列伸长或缩短,直到与参考模板的长度一致,以便其特征量与标准模式 对应。DTW 使用满足一定条件的时间规整函数描述测试序列和参考序列的时 间对应关系, 求解两模板匹配时累积距离最小所对应的规整函数。具体地, 如 果把测试序列的 N 个点在一个二维直角坐标系中的横轴上标出, 把参考序列的 M 个点在纵轴上标出, 通过这些表示帧号的整数坐标画出一些纵横线可形成一 个网络, 网络中的每一个交叉点 (n, m) 表示测试模式中某一帧的交汇点。DP 算法则可归结为寻找一条通过此网络中若干格点, 从左下角出发在右上角结束, 具有最小累积距离的路径 W。该路径通过的格点即为测试和参考模板中进行计 算的帧号。在此基础上定义轨迹的 DTW 距离公式如下:

$$D_{5}(A,B) = \min\left\{\frac{1}{K} \left[\sum_{k=1}^{K} w_{k}\right]^{\frac{1}{2}}\right\}$$
(2-6)

其中, w<sub>k</sub>是所求的规整路径 W上的第 k个值。

对 DTW 而言,即使测试序列模式与参考序列模式的时间尺度不能完全一 致,只要时间次序约束存在,它仍能较好地完成测试序列和参考序列之间的模 式匹配。但是这种方法也存在一些问题,例如,识别性能往往过分依赖于端点 检测,不能对样本做动态训练,没有充分利用信号的时序动态特性等。

■ 半监督的学习方法:

文献<sup>[16][17]</sup>中, Rowland Sillito 提出了一种对初始训练样本通过核密度估计 方法来构建 GMMs 模型的半监督学习方法。当训练样本有新进的增加时,通过 更新该 GMMs 中的部分权重、均值、方差参数,来逐步得到分类模型用于检测 出测试序列中哪些属于异常行为。具体介绍如下:

初始化设定  $N_{\text{max}}$ ,则需要求解  $N_{\text{max}}$  个高斯分布。假设有 n 个训练样本  $\{x_1, x_2, ..., x_n\}$ ,  $\sigma_1 = 0.001$ ,对于每个训练样本通过核密度估计求解对应的高斯 分布,如第 i 个训练样本  $G_i = \{\mu_i, \sum_i, \omega_i\}, i = 1, ... N_{\text{max}}$  其中,  $\sum_i = I^d \cdot \sigma_i^2$ , d是特征向量的维数。当 $n > N_{\text{max}}$ 时,将模型  $\{G_1, G_2, ..., G_n\}$ 通过混合模型合并的 方法更新为  $\{G_1, G_2, ..., G_{\text{max}}\}$ 。随着训练样本个数 n 的增加,逐次合并更新 GMMs 模型至结束。最后,通过计算测试样本与 GMMs 模型的匹配概率来判断是否属 于异常行为。

#### 2.4 基于轨迹分析的视觉目标异常行为检测研究算法简介

目前,对于异常行为检测算法研究越来越多的集中于行为分析的鲁棒性和 准确性上。经过二十多年,行为分析和识别得到了充分的发展,提出的算法越 来越多,总结起来,我们可以把这些算法归结于两个方面:轨迹表示和异常行 为检测。其中,轨迹表示方法有直接分量表示和曲线逼近两类,前者通常面临 表示序列长度不等长的困扰,可以通过插值来得到解决。后者曲线逼近表示需 要较多的计算,但可取得较好的轨迹曲线方向描述效果,因此最近几年受到越 来越多的关注,也是本文研究的研究方法之一。轨迹模式的学习方法可以分为 无监督的、半监督的和有监督的学习方法三类,通常无监督的聚类方法多数需 要预先定义聚类的数目。详细的方法对比在表 2-1 中列出。

本文采用的轨迹表示方法是基于 LCSCA 的目标轨迹表示。该算法本质上 讲就是以距离加权插值法为基础,以数据点为型值点来反求其控制点的过程。 该表示过程可以简单地总结为: 根据目标轨迹的分布趋势, 将轨迹数据序列  $T = \{(x_1, y_1), (x_2, y_2), \dots, v_{N-1}\}, (x_N, y_N)\},$ 通过非均匀三次 B 样条基函数变 换,求得表示序列 $F = \{C_1^x, C_2^x, \cdots$ ,其中,p表示所选取控制点 个数。这种方法可以为解析运动目标轨迹曲线提供了一个公共的数学表示,其 中,控制顶点和权值因子为精确表示和解析各种形状的曲线提供了充分灵活性。 在 LCSCA 的目标轨迹表示基础之上,由于异常行为检测的本质在于首先把目 标轨迹的三维时变序列数据的变换为表示序列,然后进行样本集的构建,使用 样本选择与分类的方法(分类器、稀疏表示等)从样本集中获取新的样本的运 动行为分类结果。所以,我们可以合理地做出新样本可以通过监控场景内的样 本集重构得到的假设,进而可以将监控场景中异常行为检测理解为测试样本与 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进而检测判断的过 程。在此基础上,监控场景中往往有很多的行为模式(样本集构造的模式),这 样便会导致使用样本集进行新样本重构的系数会很稀疏,样本集中的多数类别 样本对应的重构系数趋近于零,因此本文提出了基于稀疏重构分析的异常行为 检测算法,即将新样本使用训练样本集进行稀疏表达,获取稀疏重构系数和重 构误差,从而选择出最具有代表性的一些样本来表示新样本的分类,进而检测

异常。

表 2-1 基于 B 样条曲线拟合误差的控制点数的选择算法							
	轨迹表示方法		固定长	模式学习方法			无需预
	公景志云	曲绊逼近	度的表	工业权	半広叔	右收叔	定义聚
	力里衣小	四线通灯	示序列	儿血首	十血首	行血首	类数目
Johnson 等 <sup>[18]</sup>	$\checkmark$			$\checkmark$			
Owens 等 <sup>[14]</sup>	$\checkmark$			$\checkmark$			
Stauffer 等 <sup>[19]</sup>	$\checkmark$			$\checkmark$			
Hu 等 <sup>[20]</sup>	$\checkmark$		$\checkmark$	$\checkmark$			$\checkmark$
Piciarelli 和 Foresti <sup>[23]</sup>	$\checkmark$			$\checkmark$			
Piciarelli 等 <sup>[24]</sup>	$\checkmark$		$\checkmark$			$\checkmark$	$\checkmark$
Naftel 等 <sup>[26]</sup> 离散傅里叶变		N	2	J			
换+SOM		v	v	v			
Naftel 等 <sup>[26]</sup> Cheybyshev 多		N					
项式+SOM		v		•			
Rowland 等 <sup>[27]</sup> Haar 小波系							
数+ SI-GMMs							
Rowland 等 <sup>[16]</sup> 三次 B 样条		N	N		N		J
控制点+ SI-GMMs		v	v		v		v

#### 2.5 监控视频中目标轨迹获取简介

从近几年的研究内容看,目标运动轨迹这个监控视频中行为分析的研究对 象通常由视频目标跟踪实现。对于监控场景中感兴趣的运动目标,运动目标跟 踪通过对摄像机拍到的序列图像进行分析研究,计算出运动目标在连续帧图像 中的位移,给出运动参数序列的记录,运动目标的轨迹数据则记录的是每帧图 像中运动目标跟踪位置的中心点坐标。为了解决背景变化较小、视频亮度较小、 跟踪目标尺度伸缩变化大、物体局部遮挡等问题,运动目标跟踪研究人员为了 尽可能多的得到较为可靠的运动目标跟踪轨迹,做出了很大的努力,得到了一 些较成熟鲁棒的算法。例如,韩<sup>[37-40]</sup>的基于自适应样例稀疏表示的目标跟踪算 法和基于自适应特征选择的目标跟踪算法,李<sup>[31,41,42]</sup>的基于 One-Class SVM 目 标重构的跟踪算法和基于稀疏表示目标重构的跟踪算法。

本文在监控视频的轨迹研究实验中,通过收集室内大厅监控人的数据集 CAVIAR<sup>[43]</sup>和路口监控车的数据集 NGSIM<sup>[44]</sup>(Lankershim),建立包含监控视 频中的目标轨迹数据和正常/异常行为区分的样本数据库,其中室内监控人的正 常/异常行为轨迹样本共 2675 个,路口监控车的正常/异常行为轨迹样本共 1213 个。本文算法主要通过监控视频数据集 CAVIAR 的研究示意轨迹表示和异常行 为检测。

#### 2.6 本章小结

本章对目标轨迹表示算法和异常行为轨迹检测的主要研究内容、研究方法 进行了综述。首先,分别对比介绍了两类目标轨迹表示算法和三种异常行为轨 迹检测算法;然后,简单介绍了本文基于稀疏重构分析的异常行为检测算法的 基本思路;最后,简要介绍了监控视频中目标轨迹的常用获取方法和本文实验 所用的轨迹数据。

#### 第三章 基于 LCSCA 的目标轨迹表示算法

B 样条是数值分析领域里样条曲线的一种特殊表示形式,是 B 样条基曲线的线性组合。它由 Isaac Jacob Schoenberg<sup>[45,47]</sup>创造,是贝兹曲线的一般化,它的进一步推广非均匀有理 B 样条是 CAGD (Computer Aided Geometric Design 计算机辅助几何设计)的核心技术<sup>[48,49]</sup>。正是由于 B 样条具有对一般的几何曲 线建造精确模型的优势,Rowland<sup>[27]</sup>于 2008 年将三次 B 样条与函数逼近的理论 结合用于轨迹曲线的逼近表示。LCSCA 与非均匀有理三次 B 样条曲线不同,它是在非均匀有理三次 B 样条曲线定义的基础上结合函数逼近理论产生的,能够以轨迹点为二次曲线弧的型值点,按照距离加权插值后的精确计算反求得轨 迹曲线的控制点,对几何变换和投影变换具有不变性,形状设计因控制顶点和 权因子而具有灵活性。由于 LCSCA 具有优异的几何特性,它可以应用到运动目标轨迹表示中,通过对运动目标轨迹数据的数值解析得到变换后的数学表示,从而用于行为模式分类学习,并取得了较好的异常行为检测结果。

#### **3.1** LCSCA 的基本理论

#### 3.1.1 LCSCA 的提出

B 样条曲线是一种形状描述的数学方法,是 Gordon 和 Riesenfeld<sup>[49]</sup>在研究 贝兹尔曲线的基础上提出的。B 样条曲线保留了贝兹尔曲线的一切优点,克服 了贝兹尔曲线不具有局部修改性的缺点。B 样条曲线这些优异的几何特性,使 它得到在计算机辅助几何设计领域的大量应用和其他领域的推广。

**B 样条基函数**: B 样条基函数是样条函数空间中具有最小支撑的一组基, 也称为基本样条(Basic spline)。B 样条基函数有多种定义形式,例如,积分、 差分、卷积、截断幂、递推等,理论上较多采用截断幂函数的差商定义,但实 际计算中则更多采用 Deboor-Cox 递推公式<sup>[46,48]</sup>定义 B 样条基函数,这样不仅 便于计算分析基函数的性质,而且也简明直观,具有明显的几何特征。

设 $T = \{t_0, ..., t_m\}$ 是单调递增的实数序列,即 $t_i < t_{i+1}$  (i = 0, 1, ...,  $t_i$ 称为节点, T为节点向,第i 段次(或p+1阶)B样条基函数,记为 $N_{i,p}(t)$ ,定义如下:

$$N_{i,0}(t) = \begin{cases} 1 & \quad \ddot{\pi}t_i \le t \le t_{i+1} \\ 0 & \quad \breve{\pi}y \end{cases}$$
(3-1)

$$N_{i,p}(t) = \frac{t - t_i}{t_{i+p} - t_i} N_{i,p-1}(t) + \frac{t_{i+p} - t}{t_{i+p+1} - t_{i+1}} N_{i+1,p-1}(t)$$
(3-2)

并且规定:  $\frac{0}{0} = 0$ 。该定义如下图示意:



图 3-1 B 样条基函数的递归定义示意图

上述定义的 B 样条基函数具有以下性质:

1) 局部支撑性和非负性。由 B 样条基的微分差分公式,有:

$$N_{i,p}(t) = \begin{cases} \geq 0 & \quad \text{ } \ddot{\pi}t \in [t_i, t_{i+p+1}] \\ = 0 & \quad \text{ } \breve{\mu}t \end{cases}$$
(3-3)

任意给定节点区间 [t<sub>i</sub>,t<sub>i+1</sub>] 最多只有 p+1 个 N<sub>i,p</sub> 非零;可表示为
 N<sub>i-p,p</sub>(t),... 非零。

3) 规范性。对于任一 $t \in [t_i, t_{i+1}]$ ,  $\sum_{j} N_{j,p}(t) = \sum_{j=i+1-p}^{i} N_{j,p}(t) = 1$ 。

4) 除 p=0 外, N<sub>i</sub>, t)存在一个最大值。

5) 在节点区间内部, N<sub>i,p</sub>(t)任意阶可导, 而在节点处 N<sub>i,p</sub>(t)是 p-k 次可导, 其中 k 是该节点的重数。因此降低节点重数可增加连续性。

6)  $N_{i,p}(t)$ 的存在导函数可表示为:
$$N_{i,p}^{(k)}(t) = (p-1)\left(\frac{N_{i,p-1}^{(k-1)}(t)}{t_{i+p-1} - t_i} - \frac{N_{i+1,p-1}^{(k-1)}(t)}{t_{i+p} - t_{i+1}}\right)$$
(3-4)

7) 对于非周期节点向量 $T = \left\{ \underbrace{\tilde{-}}_{p+1} \\ \underbrace{-}_{p+1} \\ \underbrace{-}_{p+1} \\ \underbrace{-}_{p+1} \\ \end{bmatrix}, B$ 样条基函数还

具有以下性质:设节点个数为m+1,则有n+1个基函数,这里n=m-p-1, $N_{0,p}(a)=1$ 和 $N_{n,p}(b)=1$ 。

8) 若节点向量
$$T = \left\{ \underbrace{\begin{array}{c} \bullet \\ \underbrace{\bullet}_{p+1} \end{array}}_{p+1} \right\}, \quad \bigcup N_{i,p}(t) 变成了 p 次贝兹尔基函数。由$$

此便可说明贝兹尔基函数是 B 样条基函数的特例。

**一般 B 样条曲线:** 设 *P*<sub>0</sub>, *P*<sub>1</sub>,..., *P<sub>n</sub>* (*n* > *k*) 为给定的空间中的 *n*+1 个点,则下 列参数曲线

$$P(t) = \sum_{i=0}^{n} P_i N_{i,k}(t) \qquad t_{k-1} \le t \le t_{n+1}$$
(3-5)

为 k 阶 (k-1 次)的 B 样条曲线, 折线  $P_0, P_1, \dots, P_n$  为 P(t) 的控制多边形。 $P_i$ ,

i = 0, 1, ..., n为P(t)的控制顶点。 $N_{i,k}(t)$ 为定义在分割  $\{t_i\}_{i=0}^{n+k}$ 上的k次 B 样条 基函数,可由 Deboor-Cox 递推公式确定。B 样条有多种等价定义,其递推公式 的发现是该理论的最重要进展之一。分析以上数学定义,一般 B 样条曲线具有 以下性质:

1) 存在导数公式。由B样条基的微分差分公式,有:

$$P'(t) = \left(\sum_{i=0}^{n} P_i N_{i,k}(t)\right)'$$
  
=  $\sum_{i=0}^{n} P_i N_{i,k}'(t)$   
=  $(k-1) \sum_{i=0}^{n} \left(\frac{P_i - P_{i-1}}{t_{i+k-1} - t_i}\right) N_{i,k-1}(t)$  (3-6)

2) 表示具有唯一性。以  $\{P_i\}_{0}^{*}$  为控制顶点的 k 阶 B 样条可以唯一地表示为 公式(3-5)。

3) 规范性。当且仅当  $\{P_i\}_{o}^{*}$  退化为一点,即 $P_i \equiv A$ 时,由其所确定的 B 样条曲 线退化为一点。以下可以证明: 若 $P_i \equiv A$ ,则 $P(t) = \sum AN_{i,k}(t) = A \sum N_{i,k}(t) = A$ 。 反 之 , 若 p(t) = A , 即  $\sum P_i N_{i,k}(t) = A$  , 对 此 求 导 得 到  $(k-1)\sum \left(\frac{P_i - P_{i-1}}{t_{i+k-1} - t_i}\right) N_{i,k-1}(t) = 0$ ,因此,由 $N_{i,k-1}(t)$ 的线性无关性可知 $P_i \equiv P_{i-1}$ , 从而 $P_i \equiv A$ 。

4) 连续性。k 阶 B 样条是分段的 k-1 次参数曲线,在节点处不低于 k-1-m
 次连续, m 为节点重数。

5) 凸包性。*k*阶 B 样条的任一段,均落在相应的 *k* 个顶点之凸包内。如图
3-2 所示。以 *k*=3 为例,二次 B 样条的各段分别落在每三个顶点构成的凸包
(*P*<sub>0</sub>,*P*<sub>1</sub>,*P*<sub>2</sub>)、(*P*<sub>1</sub>,*P*<sub>2</sub>,*P*<sub>3</sub>)、(*P*<sub>2</sub>,*P*<sub>3</sub>,*P*<sub>4</sub>)、(*P*<sub>3</sub>,*P*<sub>4</sub>,*P*<sub>5</sub>)内。



图 3-2 一般 B 样条曲线的凸包性示意图

6) 局部性。改变 k 阶 B 样条的一个顶点,至多影响此点为中心的相邻 k 段曲线。

7) 直线保持性。控制多边形退化为一条直线时,曲线也退化为一条直线。

8) 几何不变性。B 样条曲线的形状和位置与坐标系的选择无关。

9) 变差缩减性局部性。设平面内 n+1 个控制顶点 P<sub>0</sub>, P<sub>1</sub>,... 构成 B 样条曲线 P(t) 的特征多边形,则在该平面内的任意一条直线与 P(t) 的交点个数不多于

该直线和特征多边形的交点个数。

一般 B 样条曲线具有很好的几何特性。以四阶三次 B 样条曲线<sup>[46-48]</sup>为例, 曲线段起止点的位置、一阶倒数、二阶倒数可直接由控制多边形的顶点位置确 定。如图 3-3 示意,计算三次 B 样条 [*t<sub>i</sub>*,*t<sub>i+1</sub>*]上的一点,要用到除*t<sub>i</sub>*,*t<sub>i+1</sub>之外的前 3 个和后 3 个,共 8 个节点的参数值。正是因为基函数是这样局部支撑的,仅 在有限区间上有值,才使得 B 样条曲线具有很好的局部修改性。由此可见,B 样条基函数的计算求解是该方法的关键,以下是求解算法 Deboor-Cox 的导出。* 



图 3-3 三次 B 样条曲线中基函数示意图

Deboor-Cox 算法: 由公式(3-1)和(3-2), 代入参数曲线公式(3-5)可以转化为:

$$P(t) = \sum_{i=0}^{n} P_{i} N_{i,k}(t)$$

$$= \sum_{i=j-k+1}^{j} P_{i} N_{i,k}(t)$$

$$= \sum_{i=j-k+1}^{j} P_{i} \left[ \frac{t-t_{i}}{t_{i+k-1}-t_{i}} N_{i,k-1}(t) + \frac{t_{i+k}-t}{t_{i+k}-t_{i+1}} N_{i+1,k-1}(t) \right]$$

$$= \sum_{i=j-k+1}^{j} \left[ \frac{t-t_{i}}{t_{i+k-1}-t_{i}} P_{i} + \frac{t_{i+k}-t}{t_{i+k}-t_{i+1}} P_{i-1} \right] N_{i,k-1}(t)$$
(3-7)

Ŷ

$$P_{i}^{(r)}(t) = \begin{cases} P_{i}, & r = 0; \ i = j - k + 1, j - k + 2, \dots \\ \frac{t - t_{i}}{t_{i+k-r} - t_{i}} P_{i}^{(r-1)}(t) + \frac{t_{i+k-r} - t}{t_{i+k-r} - t_{i}} P_{i-1}^{(r-1)}(t), & \\ r = 1, 2, \dots & \dots \end{cases}$$
(3-8)

则公式(3-8)可表示为:

$$P(t) = \sum_{i=j-k+1}^{j} P_i N_{i,k}(t) = \sum_{i=j-k+2}^{j} P_i^{(1)}(t) N_{i,k-1}(t)$$
(3-9)

上式是同一条曲线 *P*(*t*) 从 *k* 阶 B 样条表示到可 *k*-1 阶 B 样条表示的递推公式,反复应用次公式,得到:

$$P(t) = P_i^{(k-1)}(t)$$
(3-10)

于是, P(t)的值可以通过递推关系公式(3-9)求得,这就是著名的 Deboor-Cox 求解算法<sup>[46,48]</sup>。

**函数逼近:**在实际应用中,我们常常要面对用简单函数近似代替较复杂函数的问题。插值就是近似代替的方法之一,插值的近似标准是在插值点出误差为零。但应用中有时不要求具体某些点误差为零,而要求考虑整体的误差限制,这就引出了函数逼近<sup>[49-51]</sup>的概念。

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 中求函数  $p(x) \in B$ ,使 p(x) = f(x)的误差在某种意义下最小。 函数类 A 通常是区间[a,b]上的连续函数,记作 C[a,b],称为函数逼近空间;而 函数 B 通常为 n 次多项式、有理函数或分段的低次多项式等。对连续的函数空 间 C[a,b],若  $f(x) \in C[a,b]$ 可以定义以下三种常用的函数范数:

$$\|f\|_{\infty} = \max_{a \le x \le b} |f(x)| \qquad \infty - \bar{n} \mathfrak{Y}$$
(3-11)

$$\|f\|_{1} = \int_{a}^{b} |f(x)| \, dx \qquad 1 - \overline{n} \mathfrak{B} \mathfrak{B}$$
(3-12)

$$\|f\|_{2} = \left(\int_{a}^{b} |f(x)| \, dx\right)^{\frac{1}{2}} \qquad 2 - \overline{\mathbb{Z}}$$
 (3-13)

根据魏尔斯特拉斯定理<sup>[51]</sup>,则对任何 $\varepsilon > 0$ ,总存在一个代数多项式 p(x),使

$$\left\|f(x) - p(x)\right\|_{\infty} < \varepsilon \tag{3-14}$$

在区间[a,b]上一致成立。

LCSCA 就是基于上述的 B 样条基函数、一般 B 样条曲线、函数逼近理论 上提出的。

#### 3.1.2 LCSCA 的基本理论

LCSCA 的基本思想就是在非均匀有理三次 B 样条曲线定义的基础上结合 函数逼近理论产生的,能够以轨迹点为二次曲线弧的型值点,按照距离加权插 值后的精确计算反求得轨迹曲线的控制点,对几何变换和投影变换具有不变性, 形状设计因控制顶点和权因子而具有灵活性。Rowland<sup>[27]</sup>于 2008 年将三次 B 样 条与函数逼近的理论结合用于轨迹曲线的逼近表示。LCSCA 就是在 B 样条基 函数、一般 B 样条曲线、函数逼近理论基础上,采用 B 样条函数来对曲线的函 数逼近。计算时利用 Deboor-Cox 的公式(3-10) 定义的 B 样条基来算出反求控 制点的系数矩阵Φ,建立控制点序列的反算方程:

$$F^{XY} = \Phi^{\dagger} T^{XY} \tag{3-15}$$

其中,  $T^{XY}$ 表示轨迹序列,  $F^{XY}$ 表示控制点序列,  $\Phi$ 表示反求控制点的系数矩阵, 并且 $\Phi^{\dagger}=(\Phi^{T}\Phi)^{-1}\Phi^{T}$ 。

该表示算法的过程可以简单地总结为:根据目标轨迹的分布趋势,将轨迹数据序列 $T = \{(x_1, y_1), (x_2, y_2), \cdots, v_{N-1}\}, (x_N, y_N)\}$ ,通过非均匀三次 B 样条基函数变换,求得表示序列 $F = \{C_1^x, C_2^x, \cdots, p_{N-1}\}, \dots, p$ 表示所选取控制点个数。以下是当p=7时的LCSCA轨迹表示的示意:



图 3-4 p=7 时, LCSCA 轨迹表示的示意图

#### 3.2 基于 LCSCA 的目标轨迹表示算法

基于 LCSCA 的目标轨迹表示算法通过对目标轨迹的三维时变序列数据的 变换求解,为解析各种曲线表示提供了一个公共的数学表示,尤其是控制顶点 和权值因子为精确表示和解析各种形状的曲线提供了充分灵活性。算法中,首 先根据目标轨迹的分布趋势,构造参数矢量和非均匀节点矢量。接着使用计算 得到的节点矢量构造出非均匀的 B 样条基,构建反求控制点的系数矩阵,最后 本文建立了控制点反算方程,求解出控制点序列用作目标轨迹的表示。这种固 定长度的表示序列包含了运动目标的运动方向信息,解决了目标轨迹长度不一 的问题。

在获取监控视频中的目标轨迹后,本文将每条轨迹通过基于 LCSCA 的目标轨迹表示算法做出轨迹表示。具体过程如下:

1) 根据目标轨迹的分布趋势,构造参数向量和非均匀节点向量。

选取与轨迹时间信息相关的弧长比值作为参数向量 $s = \{0, s_2, \cdots, \}$ , 计算公式为:

$$s_{n} = \frac{\sum_{i=2}^{n} \sqrt{(x_{i} - x_{i-1})^{2} + (y_{i} - y_{i-1})^{2}}}{\sum_{i=2}^{N} \sqrt{(x_{i} - x_{i-1})^{2} + (y_{i} - y_{i-1})^{2}}}$$
(3-16)

其中,  $n = 2, 3, \cdots$ ,  $s_n \in (0, 1]$ 。选取控制点的个数 p, 构造非均匀的 节点向量:

2) 使用计算得到的节点向量构造非均匀 B 样条基函数。

由于一段三次 B 样条曲线只受四个控制点的影响,所以四阶三次 B 样条的基<sup>[52]</sup>的递推求解公式如下:

$$B_{p,1}(s_n) = \begin{cases} 1 & \stackrel{\text{\tiny $\underline{"}$}}{=} \tau_p \leq s_n < \tau_{p+1} \texttt{B} \\ 0 & \stackrel{\text{\tiny $\underline{"}$}}{=} \texttt{I} \texttt{th} \end{cases}$$
(3-18)

$$B_{p,4}(s_n) = \frac{s_n - \tau_p}{\tau_{p+3} - \tau_p} B_{p,3}(s_n) + \frac{\tau_{p+4} - s_n}{\tau_{p+4} - \tau_{p+1}} B_{p+1,3}(s_n)$$
(3-19)

3) 构建反求控制点的系数矩阵。

控制顶点又称 Deboor(德布尔)点,可以根据以上 Deboor-Cox 的公式(3-10) 定义的 B 样条基来求出反求控制点的系数矩阵:

$$\Phi = \begin{cases} B_{1,4}(s_1) & \cdots & s_1 \\ \vdots & \ddots & \vdots \\ B_{1,4}(s_N) & \cdots & s_N \end{pmatrix}$$
(3-20)

4) 建立控制点反算方程, 求解控制点序列。

利用非均匀三次 B 样条基解析表示轨迹数据的过程,可以由反算方程公式

(3-15)  $F^{XY} = \Phi^{\dagger}T^{XY}$ 计算。其中,控制点序列 $F^{XY} = \begin{bmatrix} c_1^X & c_1^Y \\ \vdots & \vdots \\ c_p^X & c_p^Y \end{bmatrix}$ 通过轨迹序列

$$T^{XY} = \begin{bmatrix} x_1 & y_1 \\ \vdots & \vdots \\ x_N & y_N \end{bmatrix} \Re \Phi^{\dagger} = (\Phi^{\mathsf{T}} \Phi)^{-1} \Phi^{\mathsf{T}} \mathbf{X} \boxplus .$$

之后,本文在具体研究实验中对上述所求表示序列做了归一化处理。并在 实验数据集上对控制点的个数 *p* 值做了优化选择,以提高轨迹表示的准确性。 正是由于构造节点向量与所选取的控制点个数相关,所以控制点个数的 *p* 的参 数选择需要着重加以研究。

# 3.3 基于 LCSCA 的目标轨迹表示的实验

本节总结了本章所提出的基于 LCSCA 的目标轨迹表示算法,并且在数据 集上进行实验,分析实验结果做出轨迹表示的参数优化选择。实验数据表明本 章提出的目标轨迹表示算法在目标轨迹长度不一、运动目标的运动方向多样的 问题上具有较好的效果。

#### 3.3.1 实验步骤

在上一章节 3.2 的末尾,本文提到 LCSCA 表示中控制点的个数 *p* 值需要做 些优化选择,于是,在这部分本文实验了控制点个数的优化选择。其中,基于 LCSCA 的目标轨迹表示的四个基本步骤在本文章节 3.2 中的已经详细介绍,这 里不再赘述。

本文采用根据 B 样条曲线拟合误差来选择最优的控制点个数,该算法如表 3-1:

表 3-1 基于 B 样条曲线拟合误差的控制点数的选择算法

**1. 初始化.** 读入原始轨迹的数据集 trajectories (假设有 N 个), 枚举所有的控制点数的可能值构成集合 ControlPoints (假设有 M 个);

## 2. 对集合 ControlPoints 中的一个 p 值.

2.1 计算归一化后的轨迹,即在图像中的目标水平、垂直方向坐标序列[xy];

2.2 对集合 trajectories 中的每条轨迹 trajectory;

2.2.1 LCSCA 表示下的由控制点[Cx Cy]构成 B 样条拟合曲线序列;

2.2.2 求出拟合曲线序列[Cx Cy]上各点距离轨迹 [x y]的均值 average\_distance,其中,一个拟合曲线点与轨迹的距离定义为该拟合曲 线点与所有轨迹点的最小距离;

2.3 结束 2.2 循环。计算集合 trajectories 上的误差 deviation, 其中 deviation 定义为 N 个 average\_distance 值的中值,即 deviation=median of {all average distances}。

3. 计算误差. 结束 2 的循环。得到 M 个 deviation 值。

4. 控制点数选择.选择 deviation 值的二阶变化率为零时所对应的最小 p 值。

3.3.2 测试集合及算法评估

本章所使用的运动目标轨迹测试集合为CAVIAR 室内监控人的运动轨迹测 试集。单帧图像的的坐标尺寸为 640\*460,本文为了计算方便,在计算 B 样条 曲线拟合之前对获取的轨迹坐标数据都做了归一化处理。由表 3-1 中的控制点 数选择过程可以看出,本文是在计算量和拟合误差之间做出了折衷。在本文的 基于 LCSCA 轨迹表示算法中,尽管控制点数值越大会带来更小的拟合误差值, 但我们为了能得到尽可能简单的轨迹表示,选择了尽可能小的 *p* 值同时保证了 满足拟合误差变化很小。本文是在 Intel Core(TM) i7CPU(2.93GHz) 4GB RAM 的机器上完成实验的。

# 3.3.3 实验结果及分析



(a)



图 3-5 基于 B 样条曲线拟合误差的控制点数的选择示意图 (a) 不同控制点数时的 B 样条拟合误差 (b) 不同控制点数时的 B 样条拟合误差的二阶变化率

为了形象并且量化地描述的控制点数选择过程,本文在上图中展示了基于 LCSCA 的目标轨迹表示算法中如何通过 B 样条曲线拟合误差来选择最优的控 制点数。图 3-5 (a)展示了不同控制点数对应的 B 样条拟合误差变化趋势,可 以看出,随着控制点数的增大,拟合误差值的确会越来越小。图 3-5 (b)展示 了本文是如何选择实验的控制点数的。随着控制点数的增加, 拟合误差的二阶 变化率逐渐减小,本文选择第一个二阶变化率为零的相应控制点数值, 即 *p*=6。 在此参数选择的基础上,本文做了下一章的基于稀疏重构分析的异常行为检测 研究。其中,还包括选择与 *p*=6 相近的控制点数之间的算法性能对比实验。

## 3.4 本章小结

本章总结对基于 LCSCA 的目标轨迹表示算法进行了论述和研究。首先, 根据 B 样条基函数、一般 B 样条曲线、Deboor-Cox 算法和函数逼近的理论, 概括出 LCSCA 目标轨迹表示的基本概念和用于轨迹表示的原理。接着,详细 介绍了基于 LCSCA 目标轨迹表示算法,提出控制点个数的参数选择问题需要 进一步研究。最后,通过 LCSCA 目标轨迹表示在数据集上的实验,对选择不 同的控制点个数的参数时控制点序列与原始轨迹数据的拟合情况进行了比较分 析,优化选择精确度较高的 LCSCA 目标轨迹表示。

# 第四章 基于稀疏重构分析的异常行为检测算法

# 4.1 稀疏重构分析的基本理论

## 4.1.1 稀疏重构分析综述

SRA (Sparse Reconstruction Analysis,稀疏重构分析)是近几年来信号处理, 机器学习和模式识别等领域中的一大热点研究问题。它起源于压缩感知理论, 由斯坦福大学的 David Donoho,加州理工学院的 Emmanuel Candes 以及加州大 学洛杉矶分校的陶喆轩等人提出的压缩感知理论<sup>[53-57]</sup>,是对奈奎斯特采样定理 的突破,理论中信号可以以低于奈奎斯特采样频率的频率进行采样,并且仍然 能够精确重建原始信号。

## 4.1.2 1-范数研究综述

早在范数理论创建时,许多数学研究者曾经详细研究了和分析 1-范数的性质<sup>[58]</sup>,但是在实际应用中,同样作为数学空间中某种距离度量的 2-范数则备受关注。这是因为 1-范数是指向量中每一分量的绝对值求和,它具有连续但非光滑的性质,造成其求解算法比较复杂。直到压缩感知理论在信号处理领域中的出现,稀疏表示的问题也应运产生,人们才考虑到使用 1-范数作为 0-范数的一个近似估计去重构信号。

由于 1-范数的稀疏性已经被 Candes 等在理论上得到证明,所以现在关于 1-范数的应用研究比较多。上个世纪 90 年代起<sup>[59-61]</sup>,就有一些稀疏表示的研究 成果发表。首先是 Chen 提出使用 1-范数最小化方法建立优化模型解决回归问 题,并使用基追逐法去求解。后来非常著名的 Lasso<sup>[59]</sup>算法也发表在统计学期 刊上。Lasso 算法也是针对回归问题,建立最小二乘误差和 1-范数正则化的约 束模型,并提出使用贪婪算法去求解。但是,在当时这个模型的真正意义并没 有引起很多人的注意,大多数人也没有意识到 1-范数和稀疏性之间的联系<sup>[62]</sup>。 很多学者还应用 1-范数的稀疏特性去解决图像重建、人脸识别、图像对齐等模 式识别领域的判别分类问题。例如, John Wright 和 Yi Ma<sup>[63]</sup>等人提出将 SRC

(Sparse Representation Classification 稀疏表示分类)算法应用到人脸模式识别中, 使用 1-范数最小化的稀疏表示来识别人脸。文献<sup>[63]</sup>中对一张测试人脸样本由训 练样本集进行线性的稀疏表示,为了使得这个多类回归问题的线性表示尽可能 的稀疏, SRC 算法使用 1-范数的最小稀疏重构误差来实现对人脸的识别。

#### 4.1.3 稀疏重构的基本原理

稀疏重构的基本原理是建立在压缩感知或压缩采样的理论基础之上。压缩 感知理论由 Candès、Tao、Romberg、Donoho 等创立<sup>[64]</sup>。它是指,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。



#### 图 4-1 稀疏重构模型

字典 D 的每一列为一个信号元素,信号 x 由字典 D 中的信号表示产生稀疏向量。

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使稀疏的。其 中,稀疏是指集合的大部分元素为 0,其中集合可以是向量、也可以是矩阵等 等。由于过完备字典中的信号元素具有冗余,各信号元素的表示向量之间并不 是线性无关的,因此新的信号元素可以有多种由字典库中的信号元素构成的线 性组合。稀疏重构就是找到一种由少数信号元素构成的线性组合,示意如下图 4-1。利用过完备的元素集合,将信号表示成这些少数元素的线性组合,稀疏表 示可以使得信号能量只集中于较少的元素上,非零系数的元素就揭示了信号的 主要特征和内在结构。因此,稀疏重构具有一定的抵抗噪声的能力,能够简洁 而准确地表达信号。

上述理论主要涉及变换域中的过完备字典、满足非相干性的测量矩阵和快速鲁棒的信号重建三个问题。简单概括就是,信号是否可以进行稀疏表示,如 果能进行稀疏表示,应该使用何种模型去表示,包括模型的解法这一系列问题。 压缩感知的使用 0-范数的稀疏重构模型如下公式(4-1)。

$$\begin{array}{ll}
\min_{x} & \|x\|_{0} \\
s.t. & y = Ax
\end{array}$$
(4-1)

其中, *A* 为观测矩阵, *x* 为原始信号经过稀疏变换后的表示系数, *y* 是接受端对信号进行重构之后的结果。□为 0-范数,表示系数向量非零项的个数。

因此,信号的稀疏重构问题最终转化为和式的最优化问题。当 *A* 是 *Hibernet* 空间的一个正交基时,稀疏向量容易求解,该优化问题也容易求解。然而对于 一个冗余字典却是 NP-hard 问题。关于这个问题解的存在以及是否唯一都是值 得考究的,所以在用模型 (4-1)做稀疏重构之前,没有什么理论保证。幸运地 是,Elad 和 Bruckstein<sup>[65]</sup>于 2003 年在 Donoho 和 Huo<sup>[66]</sup>的研究基础上证明,如 果矩阵 *A* 满足:  $\sigma(A) \ge 2 ||x||_0$ ,那么 0-范数最优化问题具有唯一解。 $\sigma(A)$ 指的是矩阵 *A* 中最小的线性相关的列向量集所含的向量个数。然而,虽然证明 出模型的解是存在唯一的,但是上述优化模型的求解过程是 NP-hard 的。随后, Tao 和 Candes 于 2006 年<sup>[66-67]</sup>合作证明了在 RIP (Restricted Isometry Property, 限制等距性质)条件下<sup>[64]</sup>, 0-范数优化问题与公式(4-2)中 1-范数优化问题具有相 同的解,其中,RIP 条件指稀疏信号在观测矩阵作用下必须保持几何性质相一 致。这就意味着,如果*x*在 *A* 中有非常稀疏的扩展,那么这个稀疏扩展通过算 法就可以精确重构,而且我们可以通过求解较为简单的 1-范数问题,取代原始 模型中的 0-范数问题。

# $\min ||x||_1$

$$s.t. \quad y = Ax \tag{4-2}$$

基于在 RIP 性质提出之后,稀疏表示和重构终于在理论上和实践中得到统一。后来很多研究学者也注意到稀疏重构的优点,先后将其用于模式识别和计

算机视觉等领域中,促进了该理论求解的研究发展。目前稀疏重构的求解算法 主要有: MP (Matching Pursuit,匹配追踪)方法<sup>[69]</sup>、OMP (Orthogonal Matching Pursuit,正交匹配追踪)方法<sup>[70]</sup>,、LASSO方法<sup>[59]</sup>、BP (Basis Pursuit,基追踪) 方法<sup>[71]</sup>,OPSR (Gradient Projection for sparse Reconstruction,梯度投影稀疏重 构)方法<sup>[72]</sup>和 Bregman 迭代法等。按照实现方式不同,这些算法可以分为三类: 直接优化法、迭代收缩优化法和范数正则化优化法<sup>[73]</sup>。

 直接优化法:这种方法是指直接使用 0-范数最小化作为稀疏性追求的 目标函数,优化模型与公式(4-1)的模型类似。这类优化问题的求解一般都使用 贪婪算法去求解,典型的代表算法有匹配追踪法<sup>[69]</sup>和正交匹配追踪法<sup>[70]</sup>等。

2)迭代收缩优化法:这种方法是著名 LASSO 方法。该方法是针对回归问题,建立最小二乘误差和 1-范数正则化的约束模型,并提出使用贪婪算法去求解。它可以通过不断松弛模型(4-3)中的 ε 因子,来实现迭代收缩求解。

$$\min_{x} ||Ax - y||_{2}$$
  
s.t.  $||x||_{1} \le \varepsilon$  (4-3)

范数正则化优化法:这个方法目前研究比较热门,常见的有基追踪方法
 <sup>[71]</sup>,软阈值方法(如梯度投影稀疏重构方法和 Bregman 迭代法)。

1999 年 Donoho 提出了 BP 方法,它是信号稀疏表示领域的一种新方法。 它寻求从过完备字典集合中得到信号的最稀疏的表示,即用尽可能少的基精确 地表示原信号,从而获得信号的内在本质特性。基追踪方法采用表示系统的范 数作为信号稀疏性的度量,通过最小化 1-范数将信号稀疏表示问题定义为一类 有约束的极值问题,进而转化成线性规划问题进行求解。BP 算法的优点是重建 精度高,需要的重建元素个数少,但是计算复杂度相对较高。

#### 4.1.4 稀疏重构在图像/视频处理领域的应用

随着稀疏重构理论的发展和不断突破,近几年的模式识别与计算机视觉领域的各种会议期刊都在大量研究稀疏表示和重构分析,ICCV'09 与 CVPR'10 还开设了稀疏表示和分析的专题报告<sup>[62]</sup>。稀疏重构理论越来越受到信号处理、 图像处理、模式识别等领域研究人员的关注,在很多相关的问题上得到了广泛的研究和应用<sup>[74-77]</sup>。以下本文简要介绍几个稀疏重构在图像处理领域的应用。

2008 年, Julien Mairal 等<sup>[78]</sup>提出了基于稀疏表示的图像重建,他们使用稀 疏表示对图像进行去噪,同时对较小的区域进行修复,取得良好的结果。John Wright 和 Yi Ma<sup>[63]</sup>等提出基于 SRC (Sparse Representation Classification 稀疏表 示分类)的人脸模式识别方法,对一张测试人脸样本由训练样本集进行1-范数最 小化的线性的稀疏表示,接着基于所得到一个稀疏的系数向量来求解最小稀疏 重构误差,实现人脸识别。该算法在人脸有部分遮挡的时候有很大优势,可以 自动找出被遮挡的部分,并且对该部分进行重建。Yang 等<sup>[79]</sup>提出了基于稀疏表 示的超分辨率重建。他们在图像信号具有稀疏性的基础上,在高分辨率图像和 低分辨率图像中建立两组对应的基。根据高低分辨率之间的对应性,从而他们 实现了超分辨率重建。而且,给定两组对应的基之后,算法不再需要当前待处 理图片以外的信息,即可以用一张图片就完成超分辨率重建。在图像处理的其 他很多方面,如图像融合、图像目标检测、图像恢复等领域也不断发展,提出 了令人瞩目的基于稀疏表示的算法。Han<sup>[38]</sup>将 1-范数最小化得稀疏重构应用到 多目标跟踪中,用搜索区域内的跟踪样本来线性重构需要跟踪目标,从而在视 频帧的搜索区域中找到相应的跟踪目标,该方法在目标被遮挡的情况下非常有 效。

# 4.2 基于稀疏重构分析的异常行为检测算法

稀疏重构在信号领域的巨大发展和它对噪声的良好特性,使得稀疏重构广 泛的应用于图像处理的各个领域中,本章我们将稀疏重构应用于目标轨迹分析 中,用于异常行为检测,同样取得了较好的效果。

## 4.2.1 目标轨迹的样本集构造

监控视频中基于稀疏重构分析的异常行为检测的样本集构造,就是建立监 控场景中运动目标轨迹表示的过完备集合。本文按照一定间隔获取视频序列中 运动目标的位置坐标,得到了运动目标的原始轨迹数据。然后划分监控场景的 出入口区域块,根据运动目标所经过的出入口区域块的不同来给原始轨迹数据 分别标号。接着,监控场景中所有的训练轨迹经过 LCSCA 轨迹表示算法变换 为的表示序列,最后,这些表示序列构成稀疏重构分析中的样本集合。其中,

每一条轨迹的表示序列是样本集的一个列向量。

具体地,监控场景中的每种典型正常行为分别建立样本集合,

$$A_j = \{a_j^1, a_j^2, ..., a_j^K\}$$
(4-4)

其中, *K* 表示第 *j* 种行为的轨迹样本个数。将所有行为的轨迹样本合并, 形成监控区域轨迹样本集合,如下:

 $B = \bigcup \qquad i_1^1, a_1^2, \dots, a_1^K, a_2^1, a_2^2 \dots a_2^K, \dots, a_J^K \}$ (4-5)

其中, *j*=1...*J*。*J*表示监控区域中典型正常与异常行为的种类数目。因此, 我们可以得到一个*K*×*J*条样本轨迹的监控区域行为集合*B*。



图 4-2 CAVIAR 中不同运动目标的轨迹示意图

以室内大厅监控人的数据集 CAVIAR<sup>[43]</sup>为例,场景中有 11 种由不同的出入口对构成的轨迹路线(如图 4-2 所示),再考虑到每条路线方向不同的区别,于是就有 22 种不同种类的轨迹。实验中,本文对监控场景中的大量仿真目标正

常行为的轨迹 2200 条<sup>±1</sup>(每种轨迹 100 条)做了样本集构造。利用这个样本 集,我们做了 40 个测试数据的实验。其中,测试数据包括了 21 条场景中运动 的人直接从一个入口走到另一个出口的运动轨迹数据,19 条场景中运动的人打 斗、晕倒、停留、徘徊的运动轨迹数据,如图 4-3 中的实例对比示意。

由于监控场景中往往有很多的行为模式,所以构造的样本集也很大,这便 会导致使用样本集进行新样本重构的系数会很稀疏,样本集中的多数类别样本 对应的重构系数趋近于 0。这样的稀疏重构系数在实际中保证了样本集中只有 少数和新目标轨迹相似的样本会用于新样本的重构。



图 4-3 轨迹实例和相应 LCSCA 表示示意图

(a) 正常行为轨迹实例和其 LCSCA 表示(b)异常行为轨迹实例和其 LCSCA 表示

## 4.2.2 目标轨迹的稀疏重构分析

从压缩感知理论出发,异常行为检测的本质在于使用样本选择或分类的方法(分类器、稀疏表示等)从样本集中获取新的样本的运动行为分类结果,所

<sup>&</sup>lt;sup> $\pm 1$ </sup> 感谢文献<sup>[16,17,27]</sup>作者 Rowland Sillito 在实验数据上的帮助。

以假设新的目标轨迹 LCSCA 表示序列样本可以通过以上所构造的样本集来线性重构得到,如公式:

$$B\psi \approx F_{unknow} \tag{4-6}$$

其中,  $F_{unknow}$ 是新样本的 LCSCA 轨迹表示,  $\psi = \{\psi_j^k\}, j = 1, ..., J, k = 1, ..., K$ 是 对应 B 中样本的系数向量,  $\psi_j^k$ 就是第 j 种行为第 k 个样本的重构系数。

在实际实验中,  $\psi = \{\psi_j^k\}, j = 1, ...J k = 1, ...K, 中只有 l 个是非零的系数 (<math>l \ll K$ )。在数学中, 我们将这样的矩阵称为样本的 l 稀疏表示。非零系数的 个数可以用  $\|\psi\|_0$ 来表示, 所以我们可以通过最小化  $\|\psi\|_0$ 获得样本的稀疏重构。 这个 0-范数的问题是 NP-hard 的问题。根据 4.1 章节的理论,可以通过 1-范数 最小化可以用来解决稀疏表示问题:

$$\arg\min_{x.t.} \|\psi\|_{1}$$
s.t.  $\|B\psi - F_{unknow}\|_{2} \le \varepsilon$ 
(4-7)

其中,  $\|\cdot\|_{l}$ 表示 1-范数,  $\varepsilon > 0$ 表示一个较小值。

图 4-4 是一个稀疏向量的实例,本文选取样本集 B 重构图 4-4 (a) 所示的 轨迹。样本集样本经过 1-范数最小化,从图 4-4 (b) 中可以看出,有很少的一 些系数为非零,通过这些样本重构的目标轨迹,重构错误率较低。

通过样本集 *B* 和计算得到的稀疏系数向量ψ,目标轨迹就可以通过重构来 得到,重构公式为:

$$F_{unknow} \approx B\psi = \sum_{k=1}^{K} B^{k} \psi^{k}$$
(4-8)

基于 1-范数最小化的稀疏重构,保证了该重构是很紧密的,也就是说,样本 集中样本代表着目标轨迹的某一部分或者与整条目标轨迹相似。我们从样本集 中挑选出最有代表的样本来重构目标轨迹,这样可以有效地通过稀疏重构系数 和重构误差来揭示目标轨迹的主要特征和内在结构与样本集中的哪些样本相似 一致,使得稀疏重构系数和稀疏重构误差用作轨迹分类和异常检测时具有较强 的鲁棒性。









图 4-4 目标轨迹稀疏重构分析实例 (a) 目标轨迹 (b) 稀疏重构系数 (c) 稀疏重构误差 (d) 重构比值

# 4.2.3 基于稀疏重构分析的异常行为检测

当目标轨迹重构完成,我们由公式(4-7)计算求出了其对所有样本集合 B 的稀疏系数 $\psi$ 。随后,对于每一种行为j,本文定义其对应的特征函数 $\delta_j$ 。其中 $\delta_j$ 定义为只保留轨迹样本集合 B中第j种轨迹所对应的稀疏系数,同时将其他种类样本所对应的稀疏系数都赋值为 0。基于 $\delta_j$ 的定义与集合 B,我们利用重构比值来判断目标轨迹是否属于异常行为,过程如下公式:

$$r_j(F_{unknow}) = \left\| F_{unknow} - B\delta_j(\psi) \right\|_2, \qquad j = 1...$$
(4-9)

Detect(
$$F_{unknow}$$
) = sign( $\min_{j=1...} H_i - \theta$ )  
where  $H_j = \frac{1/r_j(F_{unknow})}{\sum_{i=1}^J 1/r_j(F_{unknow})}$  (4-10)

其中, $\theta$ 表示判断阈值,在本文实验中取较小的经验值 $\theta$ =0.03。

公式(4-10)结果若 Detect(*F<sub>unknow</sub>*) <0,则目标轨迹*F<sub>unknow</sub>*为异常行为轨迹。如 图 4-4 示例,仅当所有的重构比值都大于阈值 θ 时(图 4-4 (d)中红色虚线示 意),目标轨迹才被判断为不属于异常行为。当目标轨迹被判断为不属于异常行 为时,我们还可以通过公式(4-11)将目标轨迹样本 *F<sub>unknow</sub>* 分类:

$$Classify(F_{unknow}) = \underset{i}{\operatorname{argmin}} r_{j}(F_{unknow})$$
(4-11)

其中 $r_i(\mathbf{F}_{unknow})$ 是用 $\psi$ 的特征函数值来重构 $F_{unknow}$ 时的第i个重构误差值。

本文选取当重构误差最小时的 j 为 F<sub>unknow</sub> 分类。如图 4-4 示例,图 4-4 (c)中当 j=7 时稀疏重构误差值最小。

#### 4.3 基于稀疏重构分析的异常行为检测实验

本节总结了本章所提出的基于稀疏重构分析的异常行为检测算法,并且在数据集上进行实验,分析实验结果,并且将本文的算法与本文 2.3 章节介绍的GMMs 算法进行实验对比,用实验数据表明基于稀疏重构分析的异常行为检测算法在训练样本集为小样本时具有较好的效果。

#### 4.3.1 实验步骤

基于稀疏重构分析的异常行为检测算法的基本步骤,如表 4-1 所示。

表 4-1 基于稀疏重构分析的异常行为检测算法

## 1. 初始化.

初始化目标轨迹,并且计算其特征 $F_{unknow}$ ;

2. 构造样本集.

对目标轨迹 $F_{unknow}$ 构建目标轨迹的样本集S,计算它们的特征集B;

#### 3. 获取目标轨迹稀疏重构.

3.1 使用B计算目标的稀疏系数 $\psi$ ;

3.2 初始化 *j*=1;

3.2.1 计算稀疏系数 $\psi$ 的 $\delta_i$ 的特征函数值;

3.2.2 基于样本 $S n \delta_j(\psi)$ 重构目标轨迹;

3.2.3 计算重构误差值  $r_i(F_{unknow})$ ;

3.2.4 跳转到3.2.1,直至 *j* = *J* 时结束循环。

4. 检测异常. 计算重构比值 H<sub>i</sub>用于检测。

在本文第三章的基于 LCSCA 的目标轨迹表示方法基础上,我们定义了两种表示方法用于同组比较实验。这两种表示方法分别是: *R1*,直接使用本文 3.2章节的算法所求的 LCSCA 表示序列 $F = \{C_1^x, C_2^x, \cdots, f_1, f_2^x, f_2^x, \cdots, f_n^x, f_n^x,$ 

#### 4.3.2 测试集合及算法评估

本章所使用的运动目标轨迹测试集合为CAVIAR 室内监控人的运动轨迹测 试集。为了形象并且量化地评价本章所描述的算法性能,分类和检测异常的效 果采用检测精确度 DACC (Detection ACCuracy)和正确分类率 CCR (Correct Classification Rate)来衡量,其定义如下:

$$DACC = \frac{TP + TN}{测试轨迹数}$$
(4-12)

其中, TP 是指根据算法判断为正常行为的正常轨迹数, 称作判断为真的正确率; TN 是指根据算法判断为异常的异常轨迹数, 称作判断为假的正确率。

从定义可知:算法的性能越好,其 DACC 便会越高;随着选作重构样本集

的样本数 K 的增加, DACC 的尽可能在越小的样本集取得较高值则越好,这样便可以直观地比较算法的性能。此外, CCR 越高说明算法在分类性能上也越好。本文是在 Intel Core(TM) i7CPU(2.93GHz) 4GB RAM 的机器上完成实验的。



# 4.3.3 实验结果及分析







图 4-5 是对于 *R1* 表示,选取不同的控制点个数时,DACC 和 CCR 随着重 构样本集的样本数 *K* 增加的变化曲线。图中所示结果是 10 次随机试验的平均 结果。可以看出, *p*=5 时,图 4-5 (a)的红色曲线上的检测精确度可以达到 DACC=90.42%(±3.85%),图 4-5 (b)的红色曲线的分类正确率可以达到 CCR=70.09%(±6.13%)。尤其是当重构样本集的样本很少(*K*=5)时,算法就可以取得较好的效果,DACC达到84.75%,CCR达到62.38%。





图 4-6 所示也是 10 次随机试验的平均结果。它是对于 R2 表示,选取不同的控制点个数时,DACC 和 CCR 随着重构样本集的样本数 K 增加的变化曲线。可以看出和图 4-5 所示一样, p=5 时的算法性能最好, p=7 时次之。图 4-6 (a)的红色曲线 p=5 时检测精确度可以达到 DACC=83.75% (±2.88%),图 4-6 (b)的红色曲线 p=5 时分类正确率可以达到 CCR=68.15% (±4.53%)。尤其是当重构样本集的样本很少(K=5)时,算法就可以取得较好的效果,DACC 达到 81.75%,

CCR 达到 63.81%。对比图 4-5 和图 4-6 的结果, *R1* 表示比 *R2* 表示的结果略优。 我们分析这可能是因为不同的运动目标轨迹往往有着相近的出入口坐标, 使得 表示序列中的这两维数据特征区分性不大, 导致 *R2* 表示对一些相类似的轨迹 难以分辨。但是, 这也侧面说明了 LCSCA 表示算法得到的表示序列用于样本 模式分类的特征十分有效。

此后,我们还将基于目标轨迹分析的异常行为检测算法与本文 2.3 章节介 绍的 BMVC2008<sup>[16] [17]</sup>的 GMMs 算法做了更加深入的检测性能对比,得到了两 种算法随着重构样本集的样本数 *K* 增加的 ROC 曲线对比图(如下图 4-7)。和 上述实验类似,本文在 GMMs 实验中也是采用 10 次随机试验的平均结果。在 该曲线对比图中,命中率(True Positive Rate, TPR)被定义为 TPR=TP/P,而 误报率(False Positive Rate, FPR)被定义为 FPR=FP/N。其中,*TP* 指被算法 判断为正常行为的正常样本数,*TN* 是指被算法判断为异常的异常样本数,*P* 指 测试样本中标号为正常行为的样本数,*N* 指测试样本中标号为异常行为的样本数。



图 4-7 两种方法对比的 DACC 和 ROC 曲线

如图 4-7 所示,在小样本的情况下,即重构样本集的样本数 K 较小时,本 文算法的 ROC 曲线高于 BMVC2008 的 GMMs 算法。这就意味着本文的算法(蓝 色曲线)在小样本时性能要优于 GMMs 算法(红色曲线)。经过分析,我们推 断这可能是与本文算法在小样本时就有很好的命中率(TPR 值较高)有关,然 而本文算法在大样本情况下的劣势则是因为该方法随着样本数的增加误报率增幅较大(FPR 值增长很快)。在真实的应用中,监控场景完整的运动目标跟踪轨迹常常难以收集,所以,本文算法在小样本上的性能优势就可以发挥出来。

# 4.4 本章小结

本章对所提出的基于稀疏重构分析的异常行为检测算法进行研究。首先, 介绍了稀疏重构分析的基本理论和在处理信号、图像等领域的稀疏优势,以及 1-范数的求解方法。然后,论述了目标轨迹的样本集构造、目标轨迹的稀疏重 构分析,详细说明了如何利用重构分析得到的稀疏重构系数和重构误差来检测 异常行为。最后,给出了该算法的检测结果实验,从而对算法在目标轨迹长度 不一、运动目标的运动方向多样等情况下的鲁棒性进行了验证,同时将该方法 对于训练样本集较小时的有效性与其他算法进行了比较和分析。

# 总结与展望

本文通过从样本集中获取目标轨迹表示的重构来实现目标轨迹分析的异常 行为检测。异常行为轨迹检测通常会面临以下问题:目标轨迹长度不一、运动 目标的运动方向多样、实际中样本集往往较小等。

本文首先简述了异常行为检测的研究背景和意义、国内外研究现状和目前 已存在的研究方法,分析了国内外的行为分析的研究现状以及异常行为检测算 法中存在的难题,介绍了本文的两个主要研究模块:目标轨迹表示和异常行为 检测。接着,本文在详细讨论现有的主要目标轨迹表示算法和异常行为轨迹检 测的研究方法的优劣后,提出了基于 LCSCA 的目标轨迹表示算法。同时由于 考虑到监控场景中获得的样本集中存在许多与目标轨迹相关性较小的样本,这 样便会导致样本所对应的重构系数趋向于零,使得重构系数非常稀疏,只有部 分的样本所对应的系数有效(非零),我们提出了基于稀疏重构分析的异常行为 检测算法。基于上述的两种算法,本文在 CAVIAR 室内监控人的目标轨迹测试 集上进行了选择不同参数的对比实验用来验证算法,并且将实验结果与其他算 法进行了比较。实验结果表明,基于目标轨迹的 LCSCA 表示和稀疏重构分析 的异常行为检测算法可以取得比较鲁棒的实验效果。

本文所提出算法虽然取得了一定的成功,但是仍然一些不足。例如,LCSCA 表示算法虽然解决了轨迹表示长度不一的问题,但带来了算法中的控制点个数 p 的优化选择问题;异常行为检测算法虽然解决了小样本集的问题,但其在大 样本集上较高的误报率会导致算法不够鲁棒。在将来的工作中,我们拟对算法 的这两个问题进行深入地研究,考虑在稀疏重构分析与其他基于实例的学习方 法相结合,使得所提出的异常检测方法能够降低在大样本集上的误报率,并且 仍能进行鲁棒的异常行为检测。

# 参考文献

- A. Sumpter, and A. Bulpitt. Learning Spatio-Temporal Patterns for Predicting Object Behaviour [J]. Image and Vision Computing, 2000: 649-658.
- [2]D. Makris, and T. Ellis. Automatic Learning of Activity-based Semantic Scene Model [J]. Proceedings of IEEE Advanced Video and Signal Based Surveillance, 2003: 183-188.
- [3] P. Remagnino, T. Tan, and K. Baker. Multi-agent Visual Surveillance of Dynamic Scenes [J]. Image and Vision Computing, 1998: 529-532.
- [4] 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: 135-144.
- [5] 谷军霞, 丁晓青, 王生进. 行为分析算法综述 [J]. 中国图像图形学报, 2009: 377-387.
- [6] 夏凡, 王宏. 基于局部异常行为检测的欺骗识别研究 [J]. 智能系统学报, 2007: 12-19.
- [7] G. Johansson. Visual Motion Perception [M]. Scientific American, 1975: 76-88.
- [8] J. Yamato, J. Ohya, and K. Ishii. Recognition Human Action in Time-sequential Images using Hidden Markov Model [C]. Proceedings of IEEE Conference on Computer Vision and Pattern Recognition, 1992: 379-385.
- [9] R. Polana, R. Nelson. Low-level Recognition of Human Motion [J]. Proceedings of Motion of Non-grid and Articulated Objects, 1994: 77-82.
- [10] J.W. Davis, and A.F. Bobick. The Representation and Recognition of Human Movement using Temporal Templates [C]. Proceedings of IEEE Conference on Computer Vision and Pattern Recognition, 1997: 928-934.
- [11] J. Ben-Arie, Z.Q. Wang and P. Pandit. Human Activity Recognition using Multidimensional Indexing [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2002: 1091-1104.
- [12] Y. Luo, T. Wu and J. Hwang. Object-based Analysis and Interpretation of

Human Motion in Sports Video Sequences by Dynamic Bayesian Networks [J]. Proceedings of Computer Vision and Image Understanding, 2003: 196-216.

- [13] M. Shimozaki, and Y. Kuniyoshi. Integration of Spatial and Temporal Contexts for Action Recognition by Self Organizing Neural Networks [C]. Proceedings of IEEE International Conference on Intelligent Robots and Systems, 2003: 2385-2391.
- [14] J. Owens, and A. Hunter. Application of the Self-organizing Map to Trajectory Classification [C]. IEEE International Workshop on Visual Surveillance, 2000: 77-83.
- [15] 肖雪娟. 车辆运动行为的视觉分析 [D]. 中国科学院自动化研究所硕士学 位论文, 2005.
- [16] R. R. Sillito, and R. B. Fisher. Semi-supervised Learning for Anomalous Trajectory Detection [C]. Proceedings of British Machine Vision Conference, 2008: 1035-1044.
- [17] R. R. Sillito, and R. B. Fisher. Incremental One-class Learning with Bounded Computational Complexity [C]. Proceedings of the International Conference on Artifical Neural Networks, 2007: 58-67.
- [18] N. Johnson, and D. Hogg. Learning the Distribution of Object Trajectories for Event Recognition [J]. Image and Vision Computing, 1996: 609-615.
- [19] C. Stauffer, and W.E.L. Grimson. Learning Patterns of Activity using Real-time Tracking [J]. IEEE Pattern Analysis and Machine Intelligence, 2000: 747-757.
- [20] W. Hu, X. Xiao, Z. Fu, D. Xie, T. Tan, and S.J. Maybank. A System for Learning Statistical Motion Patterns [J]. IEEE Transaction on Pattern Analysis and Machine Learning, 2006: 1450-1464.
- [21] Z. Zhang, K. Huang, and T. Tan. Comparison of Similarity Measures for Trajectory Clustering in Outdoor Surveillance Scenes [C]. Proceedings of International Conference of Pattern Recognition, 2006: 1135-1138.
- [22] Z. Zhang, K. Huang, T. Tan and L. Wang. Trajectory Series Analysis Based Event Rule Induction for Visual Surveillance [C]. Proceedings of International Conference on Computer Vision and Pattern Recognition, 2007: 1-8.

- [23] C. Piciarelli, and G.L. Foresti. Online-trajectory Clustering for Anomalous Events Detection [J]. Proceedings of Pattern Recognition Letters, 2006: 1835-1842.
- [24] 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.
- [25] 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.
- [26] A. Naftel, and S. Khalid. Classifying Spatiotemporal Object Trajectories Using Unsupervised Learning in the Coefficient Feature Space [C]. Proceedings of Multimedia Systems, 2006: 227-238.
- [27] R. R. Sillito, and R. B. Fisher. Parametric Trajectory Representations for Behaviour Classification [C]. Proceedings of British Machine Vision Conference, 2009.
- [28] 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.
- [29] 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: 831-843.
- [30] 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.
- [31] L. Li, Z.J. Han, Q.X. Ye, and J.B. Jiao. Visual Object Tracking via One-class SVM [C]. Proceedings of the 2010 international conference on Computer vision, 2010.
- [32] T. Kohonen. Self-Orgnizing Maps [M]. Springer Series in Information Sciences, Vol. 30. Springer, Heidelberg. 1997.
- [33] H.C. Liu, D.B. Wu, J.M Yih, and S.W. Liu. Fuzzy Possibility C-Mean Based on Mahalanobis Distance and Separable Criterion [C]. Proceedings of the 7th

Conference on 7th WSEAS International Conference on Applied Computer Science, 2007.

- [34] J. Lee, and J.W. Han. Trajectory Clustering: A Partition and Group Framework[C]. Proceedings of the 2007 ACM SIGMOD international conference on Management of data, 2007:593-604.
- [35] X.L. Li, J.W. Han, J.G. Lee and Hector Gonzalez. Traffic Density-based Discovery of Hot Routes in Road Networks [Z]. Lecture Notes in Comouter Science, 2007:441-459.
- [36] 郝久月,李超,高磊,熊璋.智能监控场景中运动目标轨迹聚类算法 [J]. 北京航空航天大学学报,2009:1083-1087.
- [37] Z.J. Han, Q.X. Ye, and J.B. Jiao. A Fast Object Tracking Approach Based on Sparse Representation [C]. Proceedings of 18th IEEE International Conference on Image Processing, 2011.
- [38] Z.J. Han, J.B. Jiao, B.C. Zhang, Q.X. Ye, and J.Z. Liu. Visual Object Tracking via Sample-based Adaptive Sparse Representation (AdaSR) [J]. Pattern Recognition, 2011: 2170–2183.
- [39] Z.J. Han, Q.X. Ye, and J.B. Jiao. Online Feature Evaluation for Object Tracking using Kalman Filter [C]. International Conference on Pattern Recognition, 2008.
- [40] 韩振军. 目标跟踪中的特征评估算法研究 [D]. 中国科学院研究生院硕士 学位论文, 2009.
- [41] 李莉. 基于样本空间目标重构的跟踪算法研究 [D]. 中国科学院研究生院 硕士学位论文, 2011.
- [42] L. Li, Z.J. Han, J.B. Jiao, and Q.X. Ye. Visual Object Tracking via Sparse Reconstruction [C]. Proceedings of IEEE International Conference on Internet Multimedia Computing and Service, 2010: 151-154.
- [43] R. B. Fisher, J. Santos-Victor and J. Crowley. CAVIAR test case scenarios [DB/OL]. URL http://homepages.inf.ed.ac.uk/rbf/CAVIAR/.
- [44] Cambridge Systematics Inc. NGSIM vehicle trajectory datasets [DB/OL]. URL http://ngsim.camsys.com/.
- [45] I. J. Schoenberg. Contribution to the Problem of Approximation of Equidistant

Data by Analytic Functions [Z]. Quart. Appl. Math., vol. 4,1946: 45-99.

- [46] C. de Boor. A Practical Guide to Splines [M]. New York: Springer-Verlag, 1978.
- [47] L. L. Schumaker, Spline Functions: Basic Theory [M]. New York: Wiley, 1981.
- [48] M. Unser, A. Aldroubi, and M. Eden. B-spline Signal Processing II Efficiency Design and Applications [J]. IEEE Transactions on Signal Processing, 1993: 834-848.
- [49] W.J. Gordon, and R.F. Riesenfeld. Bernstein-Bezier Methods for the Computer-aided Design of Free-form Curves and Surfaces [J]. Journal of the ACM, 1974.
- [50] 崔明根,吴勃英,王德明,丁效华编著.数值分析原理 [M].科学出版社, 2003.
- [51] 阎庆旭, 陈兆斗, 刘慧芳. Weierstrass 逼近定理的应用 [M]. 数学的实践与 认识, 2004: 174-176.
- [52] T. Hastie, R. Tibshirani, and J. Friedman. The Elements of Statistical Learning[M]. Springer Series in Statistics. Springer, 1st edition, 2001.
- [53] E. Candes, J. Romb and T. Tao. Robost Uncertainty Principles: Exact Signals Reconstruction from Highly Incomplete Frequence Information [J]. IEEE Transactions on Information Theory, 2006: 489-509.
- [54] D. Donoho. Compressed Sensing [J]. IEEE Transactions on Information Theory, 2006: 1289-1306.
- [55] R. Baraniuk. A Lecture on Compressive Sensing [J]. IEEE Signal Processing Magazine, 2007: 118-121.
- [56] R. DeVore. Deterministic Constructions of Compressed Sensing Matrics [J]. Journal of Complexity, 2007: 918-925.
- [57] D. Donoho, and Y. Tsaig. Extensions of Compressed Sensing [J]. Signal Processing, 2006: 533-548.
- [58] P.S. Bradley, O. L. Mangasarian, Feature Selection via Concave Minimization and Support Vector Machines [C]. Machine Learning Proceedings of the Fifteenth International Conference, 1998.
- [59] R. Tibshirani. Regression Shrinkage and Selection via the Lasso [J]. Journal of

the Royal Statistical Society, Series B 58, 1996: 267-288.

- [60] S.S. Chen, Basis Pursuit [D]. Ph.D. Thesis, Stanford University, 1995.
- [61] S. Mallat and Z. Zhang. Matching Pursuit with Time-frequency Dictionaries [J].IEEE Transactions Signal Processing, vol.41(12), 1993: 3397–3415.
- [62] 徐冉. 基于 1 范数最小化学习的人体检测算法研究 [D]. 中国科学院研究 生院博士学位论文, 2011.
- [63] A.Y. Yang, J. Wright, Y. Ma, and S. S. Sastry, Robust Face Recognition via Sparse Representation [J]. IEEE Transaction on Pattern Analysis and Machine Intelligence, vol. 31, No. 2, 2009.
- [64] B.S. Kashin. Diameters of Some Finite-Dimensional Sets and Classes of Smooth Functions [J]. Izv. Akad. Nauk SSSR Ser. Mathematics, vol.41(2), 1977: 334–351.
- [65] M. Elad, and A.M. Bruckstein. A Generalized Uncertainty Principle and Sparse Representation in Pairs of Bases [J]. IEEE Transactions on Information Theory, 2002: 2558-2567.
- [66] D. Donoho, and X. Huo. Uncertainty Principles and Ideal Atomic Decompositions [J]. IEEE Transactions on Information Theory, 2001: 2845-2862.
- [67] E.J. Candès, J. Romberg and T. Tao, Stable Signal Recovery from Incomplete and Inaccurate Measurements [J]. Communications on Pure and Applied Mathematics, vol.59(8), 2006: 1207–1223.
- [68] E. J. Candès and T. Tao, Decoding by Linear Programming [J]. IEEE Transactions on Information Theory, vol.51(12), 2005: 4203–4215.
- [69] S.G. Mallat, Z. Zhang. Matching Pursuits with Time-frequency Dictionaries [J].IEEE Transactions on Signal Processing, 1993: 3397-3415.
- [70] J. Tropp, and A. Gilbert. Signal Recovery from Random Measurements via Orthogonal Matching Pursuit [J]. IEEE Transactions on Information Theory, 2008: 4655-666.
- [71] S. Chen, and D. Donoho, and M. Saunders. Atomic decomposition by basis pursuit [J]. Society for Industry and Applied Mathematics Journal on Scientific Computing, 1999: 33-61.

- [72] 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: 586-597.
- [73] J.Y. Yang, Y.G. Peng, W.L. Xua, and Q.H. Dai. Ways To Sparse Representation: A Comparative Study [J]. Tsinghua Science & Technology, 2009: 434-443.
- [74] M. Wakin, J. Laska, M. Duarte, D. Baron, S. Sarvotham, D. Takhar, K. Kelly, and R. Baraniuk. An Architecture for Compressive Imaging [C]. IEEE International Conference on Image Processing, 2006: 1273-1276.
- [75] J. Ma. Single-Pixel Remote Sensing [J]. IEEE Geoscience and Remote Sensing Letters, 2009: 199-203.
- [76] S.F. Cotter, and B.D. Rao. Sparse Channel Estimation via Matching Pursuit with Application to Equalization [J]. IEEE Transactions on Communications, 2002: 374-377.
- [77] G. Taubock, and F. Hlawatsch. A Compressed Sensing Technique for OFDM Channel Estimation in Mobile Environments: Exploiting Channel Sparsity for Reducing Pilots [C]. IEEE International Conference on Acoustics, Speech and Signal Processing, 2008: 2885-2888.
- [78] J. Mairal, M. Elad, and G. Sapiro. Sparse Representation for Color Image Restoration [J]. IEEE Transaction on Image Processing, 2008: 53-69.
- [79] J. Yang, J. Wright, T. Huang, and Y. Ma. Image Super-Resolution as Sparse Representation of Raw Image Patches [C]. IEEE Conference on Computer Vision and Pattern Recognition, 2008.
# 作者简历及论文发表

姓名:李策	性别:女 出生	日期: 1988.01.04	籍贯: 山西运城
2009.9-2012.7	中国科学院研究生	院 物流工程	硕士
2004.9-2008.7	天津大学	软件工程	学士
2004.9-2008.7	南开大学	金融学	学士

已发表文章目录

•

Ce Li, Zhenjun Han, Qixiang Ye, Jianbin Jiao. Abnormal behavior detection via sparse reconstruction analysis of trajectory [C]. *Proceedings of the 6th International Conference on Image and Graphics (ICIG)*, 2011:807-810. (EI)

已接收文章目录

 Ce Li, Zhenjun Han, Qixiang Ye, and Jianbin Jiao. Visual abnormal behavior detection based on trajectory sparse reconstruction analysis [J]. *Neurocomputing*, Elsevier. (SCI)

# 附录: 主要符号对照表

BP 基追踪(Basis Pursuit) CAGD 计算机辅助几何设计(Computer Aided Geometric Design) DFT 离散傅里叶变换(Discrete Forurier Transform) 动态时间规整(Dynamic Time Warping) DTW FSM 有限状态机(Finite State Machine) GHMM 增长的隐马尔可夫模型(Growing Hidden Markov Model) 高斯混合模型(Gauss Mixture Models) **GMMs** HMM 隐马尔可夫模型(Hidden Markov Model) LCSCA 最小二乘三次 B 样条的曲线逼近(Least-squares Cubic Spline Curves Approximation) LCSS 最长公共子序列(Longest Common Subsequence) MP 匹配追踪(Matching Pursuit) 一类支持向量机(One Class Support Vector Machine) One-class SVM 正交匹配追踪算法(Orthogonal Matching Pursuit) OMP **OPSR** 梯度投影稀疏重构(Gradient Projection for sparse Reconstruction) PCA 主成分分析(Principle Components Analysis) 自组织映射(Self-Organizing Feature Map) SOM SRC 稀疏表示分类(Sparse Representation Classification)

### 致 谢

在中国科学院研究生院攻读硕士学位的学习生活中,我经历了诸多坎坷, 也付出了艰辛的努力,同时也得到了很大的收获。在毕业论文完成之际,由衷 地感谢这三年来曾经给予我无数帮助的老师、同学、朋友和家人。

首先,我要感谢导师焦建彬教授给予珍贵的求学机会,感谢他在我硕士期间每一次的指导和鼓励,感谢他在论文撰写和修改中倾注的心血。三年来,恩师对我的学习给予了悉心的指导,为我的研究提供了良好的环境和机会。他严 谨的治学态度和平易近人的学者风范深深地影响着我,他诲人不倦的精神让我 感动,这些言传身教将使我受益终生。

其次,感谢叶齐祥老师和韩振军老师。他们在我的理论学习和实验研究中 给予了耐心的指导,并在论文的撰写和审稿中付出了辛苦的劳动。他们具有渊 博的专业知识,自强不息的学习精神和扎实的动手能力,我从他们的谆谆教导 中学到了一些令我受益匪浅的可贵知识。

衷心感谢我的同学们,感谢我们一起学习生活中结下的深厚友谊,特别是 好友武博、纪颖夏、高文、汪舰航、沙月、李桂芝、刘一飞、祝耀华。三年中, 他们曾和我一起面对成长中的喜悦和困惑,一起书写硕士生活的美好回忆。在 即将毕业之际,我想感谢他们一路上的相伴,真心希望我们不会因为毕业的分 离而隔断了友情。

特别要感谢我的父母和姐姐李茜,感谢他们多年来一直给我最无私的关怀 和爱护,同时感谢男友在我郁闷沮丧时的鼓励。感谢我的父母为我所做的一切, 愿他们能够为我而骄傲,祝福他们健康长寿。亲人们对我的支持和理解指引我 奋发拼搏、积极向上,我将终生铭记。

感谢参加开题及中期评阅的各位老师和专家们,他们曾利用丰富的经验来 无私地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。

### 李策

### 2012年5月

61