

引用格式: 邓壮壮, 杨世海, 朱节中, 等. 基于 SVM 的南极望远镜驱动非预期故障诊断方法[J]. 中国测试, 2023, 49(6): 75-81.  
DENG Zhuangzhuang, YANG Shihai, ZHU Jiezhong, et al. Unanticipated fault diagnosis method for Antarctic telescope drive based  
on SVM[J]. China Measurement & Test, 2023, 49(6): 75-81. DOI: 10.11857/j.issn.1674-5124.2021080173



# 基于 SVM 的南极望远镜驱动非预期故障诊断方法

邓壮壮<sup>1</sup>, 杨世海<sup>2,3</sup>, 朱节中<sup>1</sup>, 李 运<sup>2,3</sup>

(1. 南京信息工程大学自动化学院, 江苏 南京 210044; 2. 中国科学院国家天文台南京天文光学技术研究所, 江苏 南京 210042;  
3. 中国科学院天文光学技术重点实验室(南京天文光学技术研究所), 江苏 南京 210042)

**摘 要:** 针对南极望远镜驱动系统的非预期故障检测存在先验信息不足、故障特征难确定和故障样本少等问题, 提出一种基于支持向量机 (support vector machine, SVM) 的非预期故障检测方法。以南极望远镜驱动系统为实验平台故障植入, 采集的数据中心化 and 标准化预处理。基于 KNN(K-nearest neighbor)、K-means、BP(back propagation) 神经网络和 SVM 算法建立 4 种非预期故障检测分类器, 将各个算法参数调优, 再根据数据特征预测分类。实验结果表明: 在相同的实验条件下, 基于 SVM 算法的非预期故障检测分类器性能优于其他 3 种分类器性能。将该类方法应用于半实物仿真平台, 验证该算法可行、有效。

**关键词:** 南极望远镜; 驱动系统; 非预期故障; 支持向量机; 分类器  
中图分类号: TH7; TP2; P111 文献标志码: A

文章编号: 1674-5124(2023)06-0075-07

## Unanticipated fault diagnosis method for Antarctic telescope drive based on SVM

DENG Zhuangzhuang<sup>1</sup>, YANG Shihai<sup>2,3</sup>, ZHU Jiezhong<sup>1</sup>, LI Yun<sup>2,3</sup>

(1. College of Automation, Nanjing University of Information Science & Technology, Nanjing 210044, China;  
2. National Astronomical Observatories / Nanjing Institute of Astronomical Optics & Technology, Chinese  
Academy of Sciences, Nanjing 210042, China; 3. CAS Key Laboratory of Astronomical Optics &  
Technology, Nanjing Institute of Astronomical Optics & Technology, Nanjing 210042, China)

**Abstract:** Aiming at the problems of insufficient prior information, difficulty in determining fault characteristics and few fault samples in the unanticipated faults detection of the Antarctic telescope drive system, a new method of unanticipated fault detection based on support vector machine(SVM) is proposed. Taking the drive system of Antarctic telescope as the experimental platform, fault implantation data are collected, the centralized and standardized preprocessing are carried out. Four types of unanticipated fault detection classifiers are established based on KNN(K-nearest neighbor), K-means, BP(back propagation) neural network and SVM algorithm, the parameters of each algorithm are optimized and classification is predicted according to the characteristics of data. The experimental results show that under the same

收稿日期: 2021-08-22; 收到修改稿日期: 2021-10-24

基金项目: 国家自然科学基金项目 (11973065); 天文联合基金重点项目 (U1931207)

作者简介: 邓壮壮(1995-), 男, 江苏泗洪县人, 硕士研究生, 专业方向为天文学仪器的故障诊断、故障隔离等。

通信作者: 杨世海(1973-), 男, 安徽凤阳县人, 研究员, 博士, 研究方向为天文学仪器的精密测量和运动控制、故障诊断及自愈等。

experimental conditions, the performance of the unanticipated fault detection classifier based on SVM algorithm is better than the other three classifiers. The method is applied to the hardware in the loop simulation platform to verify the feasibility and effectiveness of the algorithm.

**Keywords:** Antarctic telescope; drive system; unanticipated fault; support vector machine; classifier

## 0 引言

计算机、光学、自动控制、精密机械等领域的高新技术获得突破和发展,解决了望远镜诸多无法跨越的难题。大口径、高精度、主动光学与自适应光学等成为新一代望远镜的突出特点;同时,望远镜的使用模式也从传统的人工操作向以驱动系统为主的,自主式、无人值守、网络化远程控制、故障诊断与维护的工作模式转变<sup>[1]</sup>。

该工作模式要求驱动系统具有很高的可靠性,望远镜长期运行于无人值守的地区,特别是太空、南极等无法及时到达的场合,一旦发生故障不能及时维修,会造成错过最佳观测时机、丢失天文数据和科研工作延误等严重后果。这对于观测时间非常宝贵的望远镜而言,无疑是亟待解决的问题<sup>[2]</sup>。

根据故障类型,可以将故障分为两类:一类是预期故障,就是在故障知识库中存在的故障,这类故障存在对应的监测记录、采集手段、特征描述、处理方法和训练数据等先验信息;另一类是非预期故障,这类故障客观存在,但是故障知识库中没有记录,或缺乏、只有少量的对应先验信息<sup>[3]</sup>。

胡雷<sup>[4]</sup>指出,非预期故障检测可以根据对已知观测样本的学习,实现对已知和未知异常的识别。故针对望远镜展开非预期故障检测研究是非常有必要的,能有效提高望远镜在未知情况下的故障处理能力。驱动系统具有较高的安全性和可靠性,且故障是小概率事件,因此故障样本稀缺。传统故障诊断方法在小样本检测中效果较差,而大量文献表明支持向量机(support vector machine, SVM)<sup>[5]</sup>在小样本学习中具有优越的性能。将SVM算法应用于非预期故障检测,具有很高研究价值。现有的非预期故障检测方法,大多是以预期故障方法为基础展开研究<sup>[3]</sup>。Pimentel<sup>[6]</sup>等指出,基于统计、基于距离、基于重构、基于域和基于信息类方法是非预期故障检测常见的方法。Fernández等<sup>[7]</sup>提出了一种轴承故障检测和自动诊断方法,采用SVM算法区分正常和故障数据,用于识别故障定位并及时诊断;

Olivier等<sup>[8]</sup>介绍了一种容错模型,当过程数据与最可能的预期故障数据不充分匹配时,即被视为非预期故障,该模型可以有效地缓解由于非预期故障导致的误诊问题;金星等<sup>[9]</sup>提出了一种基于主成分分析和SVM回转窑故障诊断模型,同时引入灰狼算法对模型参数优化,实验验证改进后具有良好的检测效果;但长林等<sup>[10]</sup>研究一种振动信号分解样本熵和SVM结合的故障诊断方法,基于该模型可实现不同故障模式和尺寸的诊断。综上所述,故障领域方法已融入各个工业领域,对非预期故障研究具有借鉴意义。

李运<sup>[11]</sup>针对南极望远镜非预期故障检测提出了三种不同的方法,基于时序特征向量、基于支持向量数据描述和基于模型数据驱动设计,实验验证了该三种方法的可行性。本文基于支持向量机建立非预期故障检测分类器模型进一步研究,并与KNN<sup>[12]</sup>、K-means<sup>[13]</sup>和BP(back propagation)<sup>[14]</sup>三种非预期故障检测分类器比较。实验数据中心化和标准化预处理,以解决数据指标之间的可比性,根据特征维贡献度解决故障特征难确定问题,同时对各个算法参数调优,有助于提高算法的检测精度。相比而言,基于支持向量机的非预期故障检测算法,在两部分实验中均达到精度最优,并在半实物仿真平台验证实验结果的有效性。将SVM等非预期故障模型应用于望远镜驱动系统,具有新颖性和工程实用价值。

## 1 支持向量机原理

SVM算法思想源于最优分类超平面,样本 $\{x_i\}$ ,类别标记为 $y_i \in \{1, -1\}$ 。假设可被分类超平面 $H: \mathbf{w} \cdot \mathbf{x} + b = 0$ 分开, $\mathbf{w}$ 是超平面法向量,也是分类器权向量, $b$ 是偏置。硬间隔称为线性分类器,如图1所示。

假设训练样本均满足约束条件:

$$y_i f(x_i) - 1 \geq 0, \quad \forall i \quad (1)$$

分类间隔最大超平面即最优分类超平面 $H$ ,硬间隔即为含约束条件的优化问题:

$$\text{Min } L_{\min} = \frac{1}{2} \|\mathbf{w}\|^2 \quad (2)$$

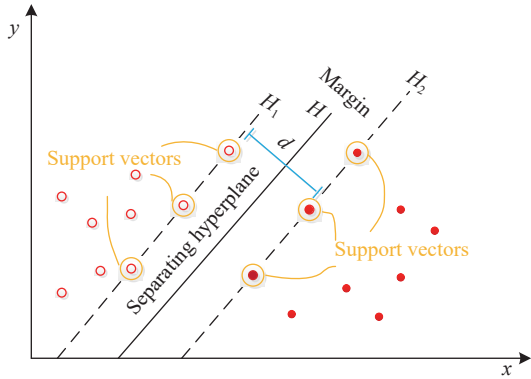


图 1 SVM 示意图

$$\text{s.t. } y_i(\mathbf{w} \cdot \mathbf{x}_i + b) - 1 \geq 0, i = 1, \dots, N \quad (3)$$

实际应用中, 大多数样本存在噪声, 即近似线性可分。引入松弛变量  $\xi_i$  和惩罚系数  $C$ , 求解软间隔最优分类超平面, Lagrange 乘子法求解, 函数转化为:

$$L_{\min} = \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^N \xi_i + \sum_{i=1}^N \alpha_i [1 - y_i(\mathbf{x}_i \cdot \mathbf{w} + b) - \xi_i] - \sum_{i=1}^N \gamma_i \xi_i, \text{ s.t. } \alpha_i \geq 0, \gamma_i \geq 0 \quad (4)$$

同样经常会遇到非线性数据, 核技巧可将线性问题推广到非线性问题中, 常用的为高斯核函数。

求解可得拉格朗日乘子集  $\{\alpha_i\}$ , 对于测试样本  $z$ , SVM 硬间隔最优分类超平面的决策函数可表示为:

$$f(z) = \mathbf{w} \cdot \mathbf{z} + b = \sum_{i=1}^N \alpha_i y_i (z \cdot \mathbf{x}_i) + b \quad (5)$$

因此, 通过 SVM 原理可实现望远镜预期正常数据和非预期故障数据的分类。实验部分以 SVM 决策函数为核心, 建立非预期故障检测的分类器模型。非预期故障识别问题转化为 SVM 的二分类问题, 即最优超平面的求解问题。

## 2 望远镜驱动系统介绍

随着观测精度要求日益提高和观测口径日趋增大, 现代大型天文光学望远镜的驱动方式, 从传统蜗轮蜗杆传动、齿轮传动和摩擦传动发展为直接驱动系统<sup>[15-16]</sup>, 并成为一种趋势。

由于驱动系统的电机整体结构庞大、成本昂贵等因素, 无法直接人为植入故障采集数据, 故借助半实物仿真平台展开研究, 该平台工作原理与驱动系统基本相同。驱动系统主要由三个部分组成<sup>[17]</sup>, 赤纬轴驱动子系统、赤经轴驱动子系统和调焦驱动子系统, 如图 2 所示。

对望远镜运行过程监测, 产生的各项参数极其



图 2 望远镜驱动系统

重要, 运行状态可根据参数分析得到。故电压、电流、功率、跟踪位置、速度、加速度和跟随误差等是望远镜运行过程中产生的主要监测参数。实验部分采集的数据指标, 主要是上述几种。当上述参数偏离了正常数据的分布, 即判定运行发生了异常。

## 3 数据选择与预处理

### 3.1 数据选择

实验数据通常包含正常数据和故障数据, 数据采集基于半实物仿真平台进行, 如图 3 所示。该平台与南极望远镜驱动系统运行机理基本相同, 采集的数据更接近南极望远镜的真实情况, 对于验证提出的非预期故障检测方法具有重要的价值。主要有 UMAC (universal motion and automation controller) 运动控制器、伺服电机和位置传感器等组成, 形成独立的控制反馈回路。



图 3 UMAC 控制器和模拟仿真平台

第一部分实验对驱动系统的转台负载故障植入。截取空载和负载运行的数据, 基于采集的数据建立非预期故障检测模型, 实现正常数据和非预期故障数据的分类, 进而转化为非预期故障识别问题。将驱动系统的转台顺时针转定义为正转, 逆时针转定义为反转。转台分别在正转低速 15 arc-second/s、正转高速 3600 arc-second/s、反转低速 15 arc-second/s 和反转高速 3600 arc-second/s 运行。基于上述 4 种运行状态采集数据, 其中空载即为正常情况, 负载为异常情况。负载实验使用螺丝阀门对转台增大摩擦力模拟故障, 拉力传感器对负载摩擦力

监测,防止摩擦力过大使得转台骤停而影响工作。驱动系统的故障植入如图4所示,通过摩擦力大小实现波动负载、递增负载和递增后稳定3种不同层次,分别模拟南极地区的环境风速干扰齿轮转动、积雪干扰齿轮转动和齿轮卡壳积雪造成转动迟滞。该部分驱动系统负载实验采集的参数有:时间(s)、Act Position、Cmd Position、Act Velocity、Cmd Velocity、Act Acceleration、Cmd Acceleration、Following Error、Motor[1].IaMeas、Motor[1].IbMeas、Motor[1].IdMeas、Motor[1].IaVolts、Motor[1].IbVolts、Motor[1].IcVolts、Motor[1].IdVolts。仿真平台与望远镜运行机理基本相同,故在实际工况中,转台的参数指标也是上述几种。理论研究表明,训练数据覆盖范围越广,模型的检测精度越高。



图4 负载故障实验植入图

第二部分实验对驱动系统的位置传感器倾斜程度不同的故障植入。传感器是驱动系统中重要的组件,研究人员通过网络化远程控制,由传感器读出望远镜的经纬轴位置等信息。转台是带动经纬轴子系统的主要部件,转台同样采取上述实验中运行的4种情况,进行位置传感器的数据采集。在植入故障前,首先要确保位置传感器避免因人为安装而造成其轻度倾斜或故障。位置传感器故障植入模拟,如图5所示,故障状态为倾斜和晃动两种不同层次,分别模拟南极地区风速的干扰、光栅毂或读数头被积雪挤压导致位置偏离。经纬轴的参数均由位置传感器读数头读出,一旦其发生故障,则影响精密仪器的运行准确性。该部分位置传感器实验采集的参数有:时间(s), Motor[1]Act Position、Cmd Position、Act Velocity、Cmd Velocity、Act Acceleration、Cmd Acceleration、Following Error, Motor[11]Act Position、Act Velocity、Act Acceleration, Motor[12]Act Position、Act Velocity、Act Acceleration。同样,在实际工况中,望远镜位置传感器的参数指标也是上述几种。

### 3.2 数据预处理

数据预处理和实验的展开部分,是基于



图5 转台和位置传感器故障实验植入图

Ubuntu18.04环境下的Matlab2018a。对负载实验数据预处理,采集的数据生成特征向量,封装在自定义data.mat文件中,该文件可同时调用正常和异常数据进行模型的训练。数据加载模块将mat文件导入SVM等算法模型中,特征向量维度由输入的15维参数组成,数据集为 $n$ 组 $\times 15$ 维度的矩阵, $n$ 为样本数量;即数据集从空载、波动负载、递增负载和递增后稳定中随机选取。

位置传感器实验数据的预处理与负载实验相同,生成自定义Data.mat文件,特征维度由输入的14维参数组成,数据集为 $m$ 组 $\times 14$ 维度的矩阵, $m$ 为样本数量;数据集从正常、倾斜和晃动分别随机选取。

采集的数据中心化和标准化预处理。数据中心化可以避免由于自身变异或者数值相差较大所引起的误差。计算公式为:

$$x' = x - \mu \quad (6)$$

式中: $x$ ——原数据值;

$\mu$ ——平均数。

不同评价指标往往具有不同的量纲和量纲单位,这样的情况会影响数据分析的结果,为了消除指标之间的量纲影响,需要数据标准化处理,使得不同特征具有相同的尺度,解决数据指标之间可比性。计算公式为:

$$x'' = (x - \mu) / \sigma \quad (7)$$

其中, $\sigma$ 为标准差。

图6(a)、(b)为负载实验数据的中心化、标准化趋势图;图6(c)、(d)为位置传感器实验数据的中心化、标准化趋势图。由于原始数据有电压、电流等一系列单位不同的数据,经过数据预处理--中心化和标准化,把有量纲表达的数据特征变成无量纲表达的数据特征。对于高维数据,便于将各指标处于同一数量级,进行综合对比评价。图6横、纵坐标,均为处理后无量纲单位,横坐标对应为数据的维度,纵坐标对应的是可以反映出不同维特征对样本表征的贡献度,便于在故障状态下,根据贡献度从高到

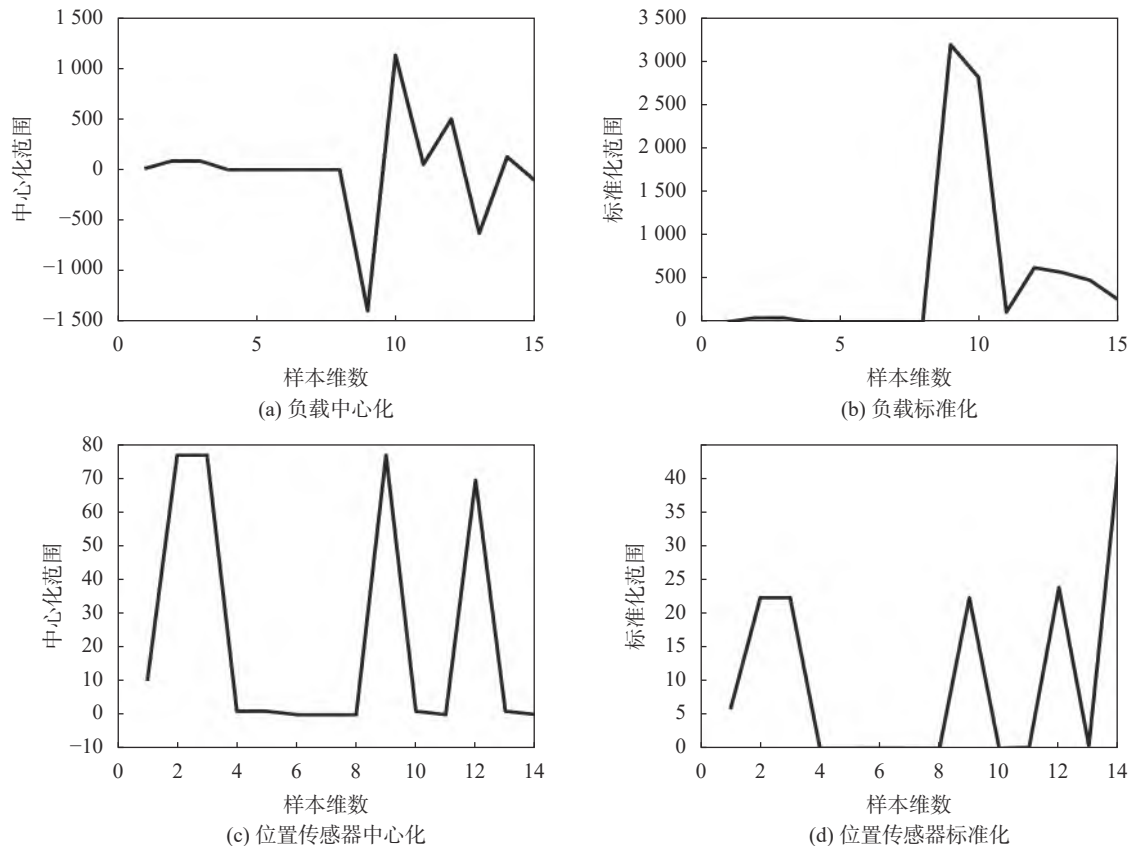


图 6 两组实验数据中心化和标准化趋势图

低逐一排查, 确定最有可能造成故障的特征维。

#### 4 非预期故障分类器模型的建立

为验证 SVM 等算法分类器的可行性和实用性, 将上述的 4 种算法分类器模型分别接入南极望远镜驱动系统中。基于上述采集的实验数据建立 SVM 等算法非预期故障检测模型, 应用系统流程如图 7 所示。

对望远镜驱动系统, 人为植入负载故障和位置传感器故障。采集的样本数据, 即为望远镜驱动系统的状态参数。通道 1 为 SVM 等算法模型的接入, 便于检测系统随机发生的非预期故障; 通道 2 为实际结果输出通道, 通过望远镜驱动控制系统模块实际输出, 再经过状态识别, 判断该望远镜的运行状态。对于实际输出只能根据经验等相关知识简单判断是否发生故障, 而对于非预期故障无处理能力。通道 1 接入 SVM 等算法模型, 模型训练数据为本实验采集 (或驱动系统历史运行数据), 可以很好地解决该类问题。将 KNN、K-means、BP 和 SVM 算法模型分别输入到驱动系统中, 进行实验验证与分析比较。非预期检测分类器利用驱动系统的状态参数作为输入, 分类结果作为输出。最后, 实际输出

与 SVM 等算法分类器输出的结果, 共同输入到状态识别中, 状态识别用于比较检测分类结果和实际输出结果, 进行决策识别驱动系统是否已经发生故障。反馈调节系统用于将识别信号输送回驱动系统中, 如发生故障, 则驱动系统停机保护或通过贡献度从高到低对故障特征维分析并自适应调节; 若未发生故障, 则正常工作。

#### 5 实验分析

本实验重点以 SVM 算法为例, 算法为典型的有监督学习。将采集的数据分为两类, 即正常类和异常类, 类别标签分别标记为  $y_i \in \{1, -1\}$ 。输入 SVM 算法的数据满足式 (1), 再结合式 (2)、(3) 和 (4) 寻求此时的最优分类超平面; 输入的测试样本根据式 (5) 决策函数进行准确分类。至此, 非预期故障识别问题转化为支持向量机的二分类问题, 即最优超平面的求解问题。

在负载实验中, 随机选取正转、反转、高速和低速状态下的数据, 并将 3 种不同层次的故障数据均用于训练, 数据随机分配为训练集和测试集。将训练集和测试集分别输入到 4 种算法中, 进行非预期故障检测精度的比较。由表 1 知, KNN、K-means、

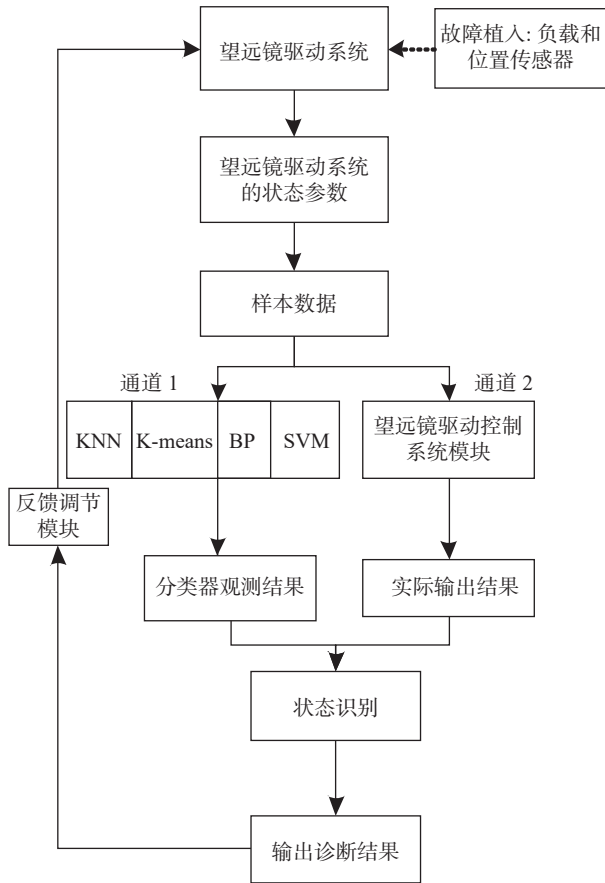


图7 非预期故障分类器模型

表1 KNN、K-means、BP、SVM分类器的性能比较

方法	负载检测准确率	位置传感器检测准确率
KNN	97.625%	76.833%
K-means	49.750%	50.000%
BP	93.625%	82.667%
SVM	98.750%	83.333%

BP和SVM的检测准确率分别为97.625%、49.750%、93.625%和98.750%。SVM算法表现的学习能力最优,在非预期故障诊断中,具有极强的学习性能,比KNN检测准确率高1.125%,比K-means检测准确率高49.000%,比BP检测准确率高5.125%。此实验中,4种算法对应的分类预测图如图8所示。

在位置传感器实验中,同样随机选取正转、反转、高速和低速状态下的数据,将两种不同层次的故障数据均用于训练。由表1知,KNN、K-means、BP和SVM检测准确率分别为76.833%、50.000%、82.667%和83.333%。其中SVM比KNN检测准确率高6.500%,比K-means检测准确率高33.333%,比BP检测准确率高0.666%。此实验中,4种算法对应的分类预测图如图9所示。在两组实验中,KNN、BP和SVM3种算法的检测精度相对较好,

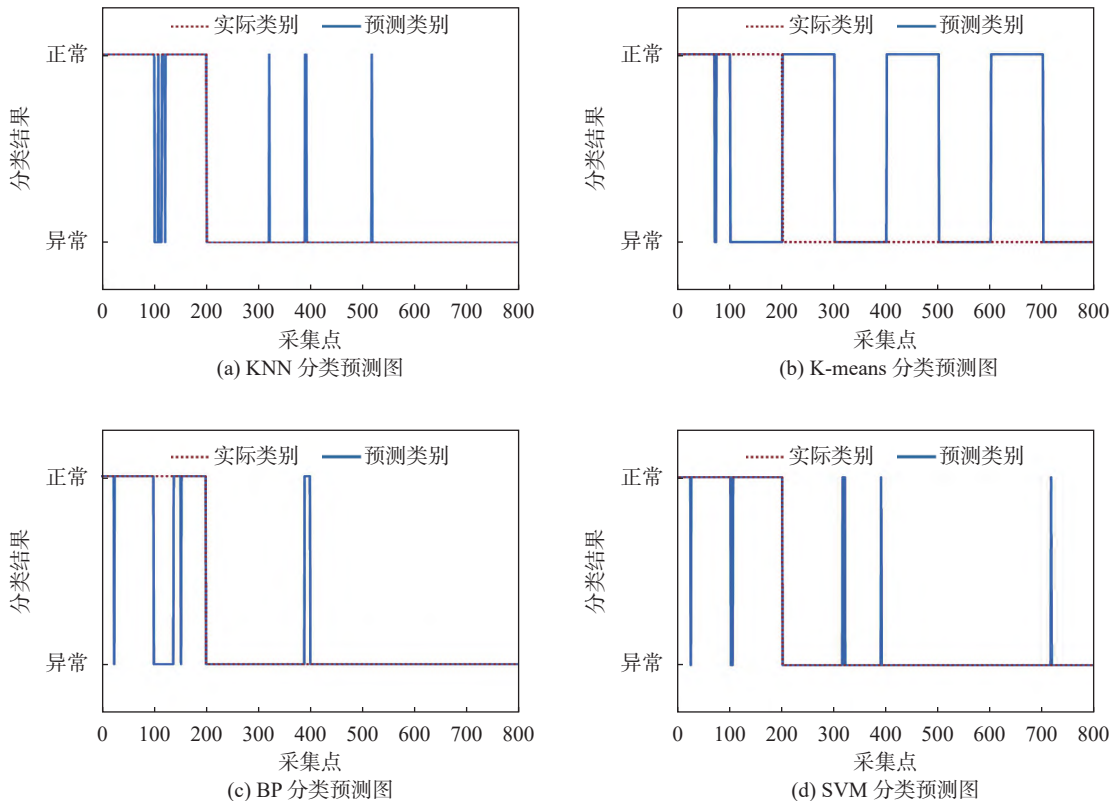


图8 负载实验 KNN、K-means、BP 和 SVM 分类预测图

其中 SVM 的表现最优; 而 K-means 表现欠佳, 检测精度最低。鉴于非预期故障研究有着很好的应用前景, 本文着力于将 SVM 算法应用在两组实验中, 实

验结果证明该算法在非预期故障检测中具有优越性。

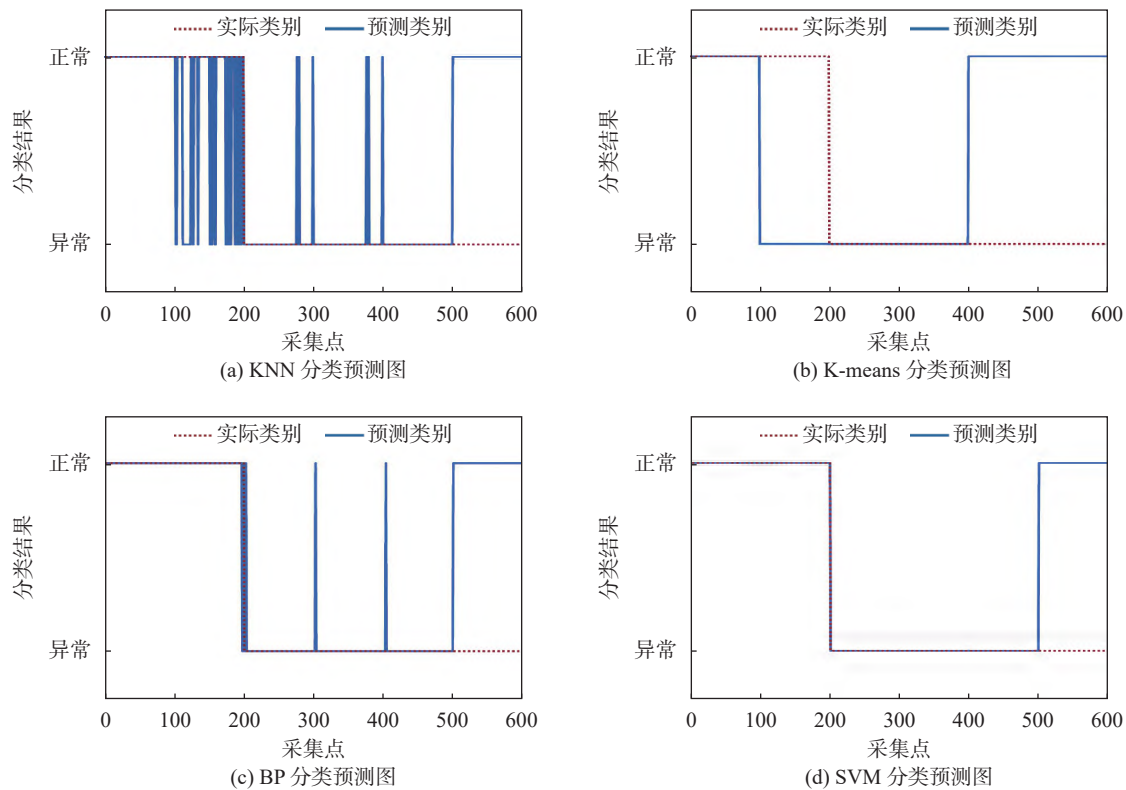


图 9 位置传感器实验 KNN、K-means、BP 和 SVM 分类预测图

由上述两部分实验, 分析可以得到出: 1) 转台在正转和反转、高速和低速的 4 种情况下, 对于不同的故障类型, SVM 算法在非预期故障检测中, 都具有较好的检测效果和应用能力; 2) 由于两部分实验精度存在差异, 该实验不仅验证了参数对于模型的检测能力有影响, 同时数据选择对于算法模型的检测结果, 也存在影响。

## 6 结束语

本文以驱动系统为研究背景, 人为使其转台增加负载、位置传感器倾斜, 偏离正常即故障状态模拟植入。将采集数据经过中心化和标准化预处理, 可反映数据不同维特征对样本表征的贡献度, 便于在故障状态下, 区分故障特征对分类结果影响的大小, 快速确定可能造成故障的特征维; 对各个算法的参数进行调参优化, 使得各个算法在非预期故障实验中, 达到最优状态。通过两组非预期故障实验, 验证了 KNN、K-means、BP 和 SVM 4 种算法的可行性, 其中以基于 SVM 非预期故障检测算法精度表现最优, 展现了其优越性和推广性。一方面, 将

其应用于望远镜驱动系统中, 具有工程实践性和新颖性; 另一方面, 可以完善非预期故障检测技术, 有效提高未知故障的检测效率。该技术研究为我国现有以及未来诸多天文望远镜、航天领域飞行器和其他研究领域等大型仪器的健康监测系统, 提供非预期故障检测的理论依据和技术支持。

此外, 该研究的不足之处有: 1) SVM 算法在四类非预期故障检测分类器中表现性能最优, 但基于 SVM 算法的非预期故障检测未能实现多分类问题, 对于输入的故障只能识别是与否, 而不能区别故障具体是哪一类; 2) 由表 1 可以看出, 各类算法检测精度目前仍然存在不可避免的误差, 检测分类器需进一步进行研究, 以期达到更优的分类检测效果。以上两点, 将是后续工作深入的方向。

## 参考文献

- [1] 李恒. 望远镜的多余度跟踪控制系统研究 [D]. 北京: 中国科学院大学, 2015.
- [2] 李运. 南极望远镜故障诊断及自愈策略研究 [D]. 北京: 中国科学院大学, 2018.

(下转第 91 页)

- 率统计升尺度预测[J]. 电网技术, 2017, 41(5): 1383-1389.
- [11] GUO Z, ZHAO W, LU H, et al. Multi-step forecasting for wind speed using a modified EMD-based artificial neural network model[J]. *Renewable Energy*, 2012, 37(1): 241-249.
- [12] LI L, ZHAO X, TSENG M, et al. Short-term wind power forecasting based on support vector machine with improved dragonfly algorithm[J]. *Journal of Cleaner Production*, 2020, 242: 118447.
- [13] 凡航, 张雪敏, 梅生伟, 等. 基于时空神经网络的风电场超短期风速预测模型[J]. *电力系统自动化*, 2021, 45(7): 28-35.
- [14] 周勇良, 余光正, 刘建锋, 等. 基于改进长期循环卷积神经网络的海上风电功率预测[J]. *电力系统自动化*, 2021, 45(3): 183-191.
- [15] 师洪涛, 杨静玲, 丁茂生, 等. 基于小波—BP 神经网络的短期风电功率预测方法[J]. *电力系统自动化*, 2011, 35(16): 44-48.

(编辑:谭玉龙)

(上接第 84 页)

- [3] 何章鸣. 非预期故障的数据驱动诊断方法研究 [D]. 长沙: 国防科学技术大学, 2015.
- [4] 胡雷. 面向飞行器健康管理的新异类检测方法研究 [D]. 长沙: 国防科学技术大学, 2010.
- [5] CORTES C, VAPNIK V. Support-vector networks[J]. *Machine Learning*, 1995, 20(3): 273-297.
- [6] PIMENTEL M A F, CLIFTON D A, CLIFTON L, et al. A review of novelty detection[J]. *Signal Processing*, 2014, 99: 215-249.
- [7] FERNANDEZ-FRANCOS D, MARTINEZ-REGO D, FONTENLA-ROMERO O, et al. Automatic bearing fault diagnosis based on one-class v-SVM[J]. *Computers & Industrial Engineering*, 2013, 64(1): 357-365.
- [8] OLIVIER L E, CRAIG I K. Model-based fault-tolerant control with robustness to unanticipated faults[J]. *IFAC-PapersOnLine*, 2017, 50(1): 1157-1162.
- [9] 金星, 邵珠超, 王盛慧. 基于 PCA 和 IGWO-SVM 水泥回转窑故障诊断研究[J]. *中国测试*, 2017, 43(10): 92-96.
- [10] 但长林, 李三雁, 张彬. 基于样本熵和 SVM 的滚动轴承故障诊断方法研究[J]. *中国测试*, 2020, 46(11): 37-42.
- [11] 李运. 极端环境下望远镜驱动系统的非预期状态研究 [D]. 北京: 中国科学院大学, 2021.
- [12] GUO G, WANG H, BELL D, et al. KNN model-based approach in classification[C] // OTM Confederated International Conferences "On the Move to Meaningful Internet Systems". Berlin Heidelberg: Springer, 2003.
- [13] HAMERLY G, ELKAN C. Learning the k in K-means[J]. *Advances in Neural Information Processing Systems*, 2004, 16: 281-288.
- [14] RUMELHART D E, HINTON G E, WILLIAMS R J. Learning representations by back propagating errors[J]. *Nature*, 1986, 323(6088): 533-536.
- [15] 李晓燕. 大型天文望远镜驱动控制方法的应用研究 [D]. 北京: 中国科学院大学, 2011.
- [16] YANG S H, LI Y, WU J J, et al. The unanticipated states of direct drive system of extremely large telescope in extreme environment[C]//Ground-based and Airborne Telescopes VIII. International Society for Optics and Photonics, 2020, 11445: 1144554.
- [17] 李运, 杨世海, 吴佳佳, 等. 基于 SVM 观测器的新异类故障检测方法及应用[J]. *振动、测试与诊断*, 2021, 41(2): 292-298.

(编辑:莫婕)