

用于铸造生产过程异常检测的 加权超球核主元分析

向观兵, 刘迎辉, 计效园, 殷亚军, 周建新

(华中科技大学材料成形与模具技术国家重点实验室, 湖北武汉 430074)

摘要: 针对铸造过程数据维度高、非线性和非高斯性的特点, 导致主元分析法存在易漏检、检测效率低等问题, 提出了加权超球核主元分析的生产过程异常检测方法。首先使用指数加权移动平均对数据平滑处理, 然后通过核主元分析法对数据核映射获得主元空间和残差空间, 最后将两个子空间信息分别输入到样本加权的支撑向量数据描述建立统计模型, 并利用建立的模型对数据进行异常检测。使用田纳西-伊斯曼过程数据和铸造的砂处理过程数据进行验证, 结果表明该方法比主元分析法具有更高的检测率。

关键词: 铸造; 异常检测; 主元分析; 支撑向量数据描述; 砂处理

作者简介:

向观兵(1996-), 男, 硕士生, 研究方向为铸造数字化监测。E-mail: 417649984@qq.com

通讯作者:

计效园, 男, 副教授。E-mail: linnjxy@foxmail.com

中图分类号: TG248

文献标识码: A

文章编号: 1001-4977(2023)06-0709-08

基金项目:

国家重点研发计划“网络协同制造和智能工厂”重点专项(2020YFB1710100); 国家自然科学基金(51905188)。

收稿日期:

2022-05-03 收到初稿,
2022-07-17 收到修订稿。

随着工业技术的进步, 铸造企业紧紧抓住智能制造带来的重大机遇, 对铸件产品的质量、生产效益的要求越来越高^[1]。铸造是一个从无到有、混批、长流程的热加工手段, 工艺参数波动大且相互影响, 导致我国高端装备复杂铸件生产存在合格率低、质量波动大等短板, 生产过程不稳定从而产生铸件缺陷, 因此需要及时掌握铸造生产过程的运行情况, 快速准确地监测到生产过程中出现的异常情况, 减少参数波动。通过对铸造生产过程运行状态进行监测, 现场的操作人员能够实时掌握生产的优劣情况, 及时发现异常信息, 对后续的生产情况进行调整改进^[2]。

基于数据驱动的方法不需要建立精确的数学模型, 通过分析和挖掘生产过程中的数据来获得工业过程运行状态。随着计算机技术、物联网技术、通信技术的发展, 可以通过一系列传感器和数据收集设备采集工业过程中的生产数据, 丰富的数据中蕴含着大量的运行状态信息, 这些采集的数据可以反映温度、压力的过程变化, 为基于数据驱动的方法提供了充足的数据支撑^[3-4]。基于数据驱动的方法主要包括统计分析方法和机器学习方法两种^[5]。

多变量统计方法中最常使用的是主元分析法(Principle Component Analysis, PCA)和偏最小二乘法(Partial Least Squares, PLS)^[6-7]。多变量统计方法主要借助统计学理论, 分析过程的历史数据并训练模型, 构造异常判断的统计控制量, 与正常生产过程中提取的统计指标作对比, 从而进行异常检测。李斌锋^[8]、郑煜^[9]建立了基于PCA的多变量统计过程控制模型, 用于监控砂处理过程的波动情况。在使用传统的PCA方法监测时只能处理各变量之间线性相关问题, 有很多学者使用核主元分析(Kernel Principle Component Analysis, KPCA)处理非线性问题。Wang X G^[10]针对非线性多模式过程的监控, 将相似性度量方法(SM)和核主成分分析(KPCA)相结合, 构造了SM-KPCA监控方案, 不同的监测效果需要增加不同的权重, 简化了监测模型结构。李景哲^[11]针对高含硫天然气净化过程数据呈现非线性、非高斯性和时序自相关的特点, 传统的PCA方法适用性不强, 提出基于动态核独立分量分析的

故障检测与诊断方法，达到比较好的监控效果。

砂型铸造生产过程发生复杂物理化学变化，综合受到人、机、料、法、环不确定因素的影响，表现出非线性、强耦合、过程数据非高斯分布等特点，这样使用PCA、KPCA方法进行监测都达不到令人满意的效果。PCA只能处理变量之间的线性相关关系，KPCA方法能处理变量之间的非线性关系，不能解决数据的分布问题，需要在已有方法的基础上进行改进以解决数据非线性相关与非高斯分布的问题。

常用的机器学习算法有支持向量机（Support Vector Machine, SVM）、高斯混合模型（Gaussian Mixture Model, GMM）、支持向量数据描述（Support Vector Data Description, SVDD）等。SVDD是一种单值分类器，能够处理非线性问题且训练的数据不受分布特征的影响。夏蓓鑫^[12]基于支持向量数据描述提出了D控制图和D-MCUSUM控制图，分别用来监控制造过程的小偏移异常和制造过程的大偏移异常。林桐^[13]等提出了一种基于超球优化SVDD的滚动轴承故障检测方法，通过超球优化改善特征向量的空间分布以降低数据描述任务的难度，超球优化SVDD比传统的SVDD方法效果更优。

综上所述，传统的PCA方法在进行异常检测时需

要满足数据服从高斯分布的假设和过程线性的假设，而铸造生产过程具有数据维度高以及数据的非线性与非高斯性，导致PCA方法产生较多的误报或者漏报，KPCA与SVDD可以在一定程度上解决上述问题^[14]。本研究提出加权超球核主元分析（Exponential Smoothing Kernel Principal Component Analysis-Weighted Support Vector Data Description, EKPCA-WSVDD）的生产过程异常检测方法，使用KPCA解决非线性问题，样本加权的SVDD解决非高斯性问题，同时还引入指数加权移动平均（Exponentially Weighted Moving Average, EWMA）对数据进行平滑处理。

1 基于EKPCA-WSVDD的异常检测方法

本研究结合KPCA和SVDD方法来处理非线性与非高斯分布的问题（如图1所示），EWMA通过对数据平滑处理对历史数据信息进行累积，对KPCA的输入数据进行预先处理，可以提高对中小偏移的检测能力。将KPCA分解得到的主元子空间和残差子空间分别输入到样本加权的SVDD中进行训练，将得到的 D_1 、 D_2 统计量代替KPCA的 T^2 、 SPE 统计量。

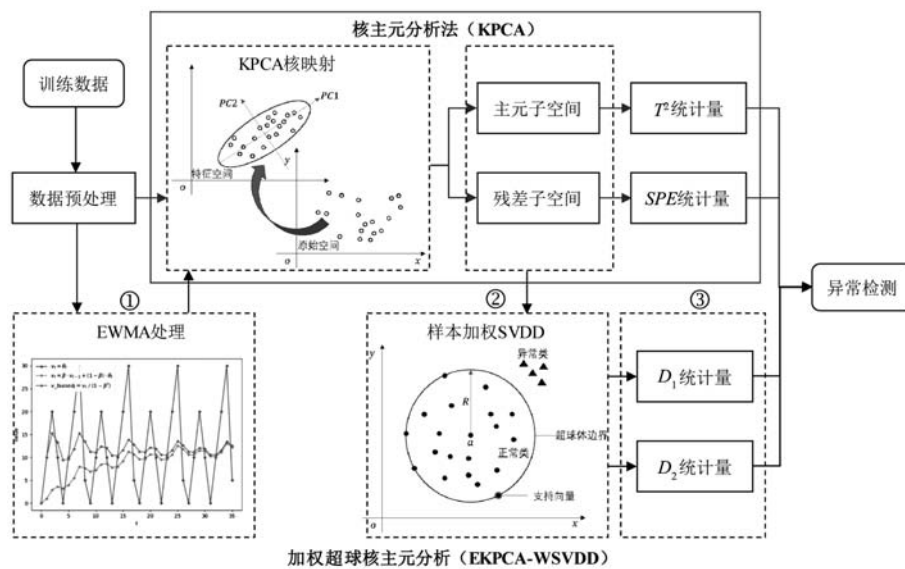


图1 加权超球核主元分析异常检测方法

Fig. 1 Detection method of the EKPCA-WSVDD anomaly

1.1 核主元分析法

目前解决非线性问题常用的是使用核主元分析法（KPCA），核主元分析法是对PCA的非性扩展^[15]，运用核函数的思想，将输入空间从低维的非线性空间映射到高维的线性空间，在高维的特征空间中使用线性

PCA计算主元，进而进行监测。

给定样本数据集 X ， $X \in R^{n \times m}$ ， n 表示样本的数量， m 表示变量的个数，从原始数据空间到特征空间 F 的映射函数为 ϕ ，假设特征空间中的样本点是中心化的，即 $\sum_{i=1}^n \phi(x_i) = 0$ ，则特征空间上的协方差矩阵可表示为式

(1), $\phi(x)$ 表示特征空间中的数据。

$$C^F = \frac{1}{n} \sum_{i=1}^n \phi(x_i) \phi(x_i)^T \quad (1)$$

KPCA求解对应的特征值分解问题:

$$C^F v = \frac{1}{n} \sum_{i=1}^n \phi(x_i) \phi(x_i)^T v = \lambda v \quad (2)$$

式中: λ 和 v 分别是协方差矩阵 C^F 的特征值和特征向量。由于映射后的数据是未知的, 投影方向无法直接求得。将每个样本与式(2)做内积得到:

$$(\phi(x_k) \cdot C^F v) = \lambda (\phi(x_k) \cdot v) \quad (3)$$

式中: $k=1, \dots, n$, 考虑到 C^F 的特征向量 v 可以由 $\phi(x_k)$ 线性表示为:

$$v = \sum_{i=1}^n \alpha_i \phi(x_i) \quad (4)$$

合并式(3)和(4), 可以得到:

$$\begin{aligned} & \frac{1}{n} \sum_{i=1}^n \alpha_i \left(\sum_{j=1}^n \phi(x_k) \cdot \phi(x_j) \phi(x_j) \phi(x_i) \right) \\ & = \lambda \sum_{i=1}^n \alpha_i (\phi(x_i) \cdot \phi(x_k)) \end{aligned} \quad (5)$$

式(5)涉及特征空间两个内积运算, $k=1, 2, \dots, n$, 定义一个 $n \times n$ 维核矩阵 K , $K_{ij} = K(x_i, x_j) = (\phi(x_i) \cdot \phi(x_j))$, 则式(5)可以简化为:

$$n\lambda\alpha = K\alpha \quad (6)$$

在特征空间 F 上进行主元计算时, 首先要进行标准化处理, 即用式(7)中的 \bar{K} 代替原来的 K , 这里 I_n 等于 $1/n$ 与一个 $n \times n$ 的单位矩阵相乘。

$$\bar{K} = K - I_n K - K I_n + I_n K I_n \quad (7)$$

在上述空间中进行PCA分析就是求解式(6)的特征值问题, 设 $\lambda_1 > \lambda_2 > \dots > \lambda_n$ 为其特征值, $\alpha_1 > \alpha_2 > \dots > \alpha_n$ 为对应的特征向量。可以得到核主元空间的主元在特征向量空间 V^k 上的投影为:

$$t_k = (v^k \cdot \phi(x)) = \sum_{i=1}^n \alpha_i^k (\phi(x_i) \cdot \phi(x)) = \sum_{i=1}^n \alpha_i^k K(x_i, x) \quad (8)$$

使用核主元分析法对非线性生产过程进行多变量统计过程监测也是通过 T^2 统计量控制图和 SPE 统计量控制图来反映。 T^2 统计量与 SPE 统计量分别由式(9)和(10)计算, Λ^{-1} 是主成分对应的特征值构成的对角阵的逆矩阵, n 为样本数量, k 为选择的主元个数。

$$T^2 = [t_1, t_2, \dots, t_k] \Lambda^{-1} [t_1, t_2, \dots, t_k]^T \quad (9)$$

$$SPE = \|\phi(x) - \phi_k(x)\|^2 = \sum_{i=1}^n t_i^2 - \sum_{i=1}^k t_i^2 \quad (10)$$

1.2 支持向量数据描述

支持向量数据描述是在支持向量机理论上发展而来的单值分类方法, 是无监督机器学习方法, 训练的数据不需要满足服从任何分布的假设, 其主要思想是通过使用核函数将数据映射到高维特征空间中, 在特

征空间中寻找一个超球体, 这个超球体尽可能包含更多的数据, 同时超球体的半径又尽可能小^[16]。这个超球体就是分类器, 位于超球体边界上的数据为支持向量, 超球体内的样本为正常样本, 外部的样本为检测出的异常样本。

这个超球体的圆心为 a , 球体半径为 R , 计算超球体的数学模型如公式(11)所示:

$$\begin{cases} \min R^2 + C \sum_{i=1}^n \zeta_i \\ \text{s.t. } \|x_i - a\|^2 \leq R^2 + \zeta_i \end{cases} \quad (11)$$

式中, ζ_i 为松弛变量, $\zeta_i \geq 0, i=1, 2, \dots, n$, 它的引入是为了避免过拟合问题; C 为惩罚因子, 用来调节模型分类错误率。引入拉格朗日乘子 α_i , 将其转换为拉格朗日对偶问题, 如公式(12)所示。可以借助核函数的思想, 用核函数 $K(x_i, x_j)$ 代替内积函数 $(x_i \cdot x_j)$ 。

$$\begin{cases} \max L = \sum_{i=1}^n \alpha_i (x_i \cdot x_i) - \sum_{j=1}^n \sum_{i=1}^n \alpha_i \alpha_j (x_i \cdot x_j) \\ \text{s.t. } \sum_{i=1}^n \alpha_i = 1, 0 \leq \alpha_i \leq C \end{cases} \quad (12)$$

根据Kuhn-Tucker条件可知, 超球体的球心 a 和超球体半径 R 计算如公式(13)所示:

$$\begin{cases} a = \sum_{i=1}^n \alpha_i x_i \\ R^2 = \|x_k - a\|^2 = x_k^2 - 2 \sum_{i=1}^n \alpha_i K(x_k \cdot x_i) + \sum_{j=1}^n \sum_{i=1}^n \alpha_i \alpha_j K(x_i \cdot x_j) \end{cases} \quad (13)$$

式中: R 为超球体上任意一个支持向量到超球体圆心的距离; x_k 为支持向量, 通过上述过程就可以获得超球体模型。常用的核函数包括线性核函数、高斯径向核函数、多项式核函数等。

1.3 改进的EKPCA-WSVDD异常检测方法

1.3.1 数据预处理

虽然在数据采集时尽可能保证了数据的准确性, 但是数据难免存在一定的噪声和异常点, 同时为了避免数据的量纲对数据处理分析结果的影响, 需要进行数据预处理。数据预处理主要包括剔除异常值、空值处理和数据标准化。

1.3.2 指数加权移动平均处理

EWMA利用了所有的历史数据, 能对数据进行平滑处理, 能够增强变量之间的相关性, 同时能够处理具有序列相关性的数据, 减小前后时刻观测值对数据的影响^[17]。

设 x_i 为变量第 i 时刻的观测值, 则EWMA统计量 z_i 可以用公式(14)进行描述。式中 λ 是加权因子, 且

$0 < \lambda \leq 1$, λ 的取值根据不同的场合而定。EWMA统计量的初始值一般取 $z_0 = E(x) = \mu$ 。

$$z_i = \lambda x_i + (1 - \lambda) z_{i-1} \quad (14)$$

将预处理后的历史数据作为EWMA的过程输入,对于不同的过程选择合适的加权因子,对数据平滑处理以增强变量间的相关性。经过EWMA处理的数据作为核主成分分析法的输入向量。

1.3.3 建立KPCA模型

选择合适的核函数,对处理后的核矩阵在特征空间中做主元分析,将特征值从大到小排序后,使用累计贡献率法来确定核主元模型的主成分个数。经过上述过程后建立正常情况下的核主元模型,保留前 k 个主元,得到的主元得分矩阵为 $T = [t_1, t_2, \dots, t_k]$ 和残差空间 E 。

1.3.4 训练加权SVDD超球体

SVDD对于在空间中分布均匀的样本分类精度较高,训练样本集中可能有远离大多数样本的部分样本,传统的SVDD没有考虑到这些样本在空间中的聚集程度对算法分类的影响,超球体可能无法准确反映目标数据特征,从而降低分类精度^[18-19]。为解决上述问题,使用样本在原始空间中的空间位置分布,对应的为每个样本引入距离权重 ρ 。使用样本点到样本中心的欧氏距离来衡量权重系数 ρ 。

$$\begin{cases} \rho(t_i) = 1 - \frac{D(t_i) - D_{\min}}{D_{\max} - D_{\min}} & (D_{\text{avg}} \leq D(t_i) \leq D_{\max}) \\ \rho(t_i) = \left(1 - \frac{D(t_i) - D_{\min}}{D_{\max} - D_{\min}}\right) + \varepsilon & (D_{\min} \leq D(t_i) \leq D_{\text{avg}}) \end{cases} \quad (15)$$

$$\begin{cases} D(t_i) = \|t_i - a\| \\ a = \frac{1}{N} \sum_{i=1}^N t_i \end{cases} \quad (16)$$

式中: $D(t_i)$ 为样本到样本中心的欧氏距离; a 为样本中心; D_{\max} 为样本到样本中心的最大距离; D_{\min} 为样本到样本中心的最小距离; D_{avg} 为样本到样本中心的平均距离; ρ 为大于1的整数。

通过式(15)可以获得每个样本的距离权重,可以用来衡量数据的空间分布情况,权重系数越大,表示样本到样本中心的距离越近且分布越密集;权重系数越小,表示样本到样本中心的距离越远且分布越稀疏。引入权重系数后的加权SVDD算法的目标函数如下:

$$\begin{cases} \min R^2 + C \cdot \rho(t_i) \sum_{i=1}^n \xi_i \\ \text{s.t. } \|t_i - a\|^2 \leq R^2 + \xi_i \end{cases} \quad (17)$$

1.3.5 实施监测

对主元空间和残差空间分别建立的超球体球心为 a_1 、 a_2 和超球体半径为 R_1 、 R_2 ,以 R_1 和 R_2 作为两个超球体的统计量控制限,测试样本到超球体球心的距离为 D_1 和 D_2 作为新的统计量,对应的控制图分别为 D_1 控制图和 D_2 控制图。

$$\begin{cases} D_1 = \|t_{\text{new}} - a_1\| \\ D_2 = \|t'_{\text{new}} - a_2\| \end{cases} \quad (18)$$

对于新的监测数据 X_{new} 同样经过上述几个过程处理,将基于距离的统计量 D_1 与控制限 R_1 相比较,如果满足 $D_1(t_{\text{new}}) \leq R_1$,则数据为正常样本,继续保持对生产过程的监测,否则可以推断出 X_{new} 数据是异常样本,进行异常结果预警与处理。对于统计量 D_2 的判别方式也是一样的。 D_1 与 D_2 中有一个控制图检测出异常表明生产过程发生了严重的变化,需要结合两个控制图对生产过程状态进行判断。

基于改进核主元分析的生产过程异常监测方法主要包括建立模型阶段和在线监测阶段,首先采集正常过程样本数据并对数据进行指数加权移动平均处理,其次利用核主元分析法对数据进行降维得到得分矩阵,然后将得到的主元空间和残差空间信息输入到加权支持向量数据描述模型中构建统计量的控制限,最后实时在线监测利用控制限判断异常情况。详细的异常检测方案如下:

(1) 建立模型阶段

Step1: 采集正常生产过程中的数据作为历史数据 $Z \in R^{n \times m}$,并对数据进行标准化处理 \bar{Z} 。

Step2: 对数据的每个变量进行指数加权移动平均平滑处理,得到矩阵 X 。

Step3: 将矩阵 X 作为KPCA算法的输入向量,计算中心化的核矩阵,建立核空间中的主元模型,选择合适的主元个数,得到主元空间 T 和残差空间 E 。

Step4: 通过计算基于欧式距离权重得到权重系数,对主元空间和残差空间分别构建基于加权的支持向量数据模型,调整模型参数值,获得超球体的圆心 a_1 、 a_2 和半径 R_1 、 R_2 ,建立 D_1 和 D_2 控制图。

(2) 在线监测阶段

Step1: 在线监测的新数据为 Z_{new} ,使用建模阶段的均值和方差进行标准化处理得到 \bar{Z}_{new} 。

Step2: 对数据的每个变量进行指数加权移动平均平滑处理,得到矩阵 X_{new} 。

Step3: 利用建模阶段KPCA的装载矩阵 P ,计算得到新数据的主元空间信息矩阵 T_{new} 和残差空间信息矩阵 E_{new} 。

Step4: 将两个信息矩阵输入到前面构建的加权支持向量数据模型,计算用于监测的统计量指标 D_1 与

D2。

Step5: 进行生产状态判断, 如果统计量指标满足 $D1 \geq R1$, 则表明检测到生产过程出现了异常, 进行异常预警, 否则说明生产过程正常运行处于可控状态。统计量D2同理。

2 模型验证

2.1 TE 过程仿真

田纳西伊斯曼 (Tennessee-Eastman, TE) 过程就是美国的田纳西伊斯曼公司开发的一个针对化学工艺过程的标准化仿真平台, 目前被广泛用在评估过程控制和检测方法中。TE过程由连续搅拌式反应釜、冷凝器、气液分离塔、汽提塔和离心式压缩机等多个单元组成^[20]。

TE过程共有52个变量, 这些变量包括41个测量变量和11个操作变量, 采样间隔3分钟。工况包括正常工况和21种可操作的故障工况, 其中有16种故障是已知的, 剩余的故障情况未知。在正常情况下, 取500组平稳运行的数据作为训练样本, 数据的维度为 500×52 , 在21种故障情况下取960个样本作为测试样本, 数据的维度为 960×52 , 在测试样本的第161个引入故障。使用异常检测率指标对检测效果进行有效评估。

分别建立PCA、KPCA、SVDD和EKPCA-WSVDD的监测模型。对TE过程的21种故障的检测率如图2所示, EKPCA-WSVDD模型的D2控制图对21种故障的检测率基本都是最高的。表1展示了故障1、4、10、12、20五种典型故障的异常检测率。对于故障10、15、20来说, EKPCA-WSVDD模型的异常检测率高于其他模




图2 21种故障检测率对比图

Fig. 2 Comparison chart of 21 fault detection rates

表1 部分故障检测率
Table 1 Partial fault detection rates %

故障 序号	PCA		KPCA		SVDD	EKPCA-WSVDD	
	T^2	SPE	T^2	SPE	D	D_1	D_2
1	99.375	99.875	99.375	99.875	99.75	99.625	99.875
4	54.125	100	52.125	100	97.625	47.375	100
10	45.5	72.125	44.5	77.125	70.25	92	95.375
15	5.5	21.125	5.25	27.25	30.25	61.75	55.75
20	40.625	69.625	39.25	75.375	73.75	70.875	90.25

型。对TE过程的仿真结果表明, 相比于三种经典的方法, 提出的EKPCA-WSVDD方法对异常情况有更好的监测效果。

2.2 铸造砂处理过程验证

铸造过程涉及复杂的物理、化学变化, 影响最终铸件质量的因素众多, 其中与铸件质量关系最密切的是砂处理和熔炼浇注部分, 大部分的缺陷问题都是由金属液质量和型砂质量不足引起的。型砂的循环过程基本贯穿了铸造生产过程的全部环节, 控制型砂的质量对整个铸造过程有重要的意义, 以砂处理过程的异常检测过程为例说明本方法的应用。

型砂的组分是影响型砂性能的主要原因之一, 通常需要检测型砂的组分 (旧砂、新砂、水分、膨润土、煤粉等) 和反映型砂质量的 (紧实率、湿压强度、剪切强度、透气性、旧砂温度、含水量等), 如果这些参数设置不当会造成砂眼、粘砂、气孔等缺陷^[21]。

本研究使用HL铸造厂的型砂检测数据, 收集到转向桥壳铸件在2021年12月的1 256条数据, 经过筛选除掉一些不可用数据后, 得到1 145条正常生产过程的数据和49条产生砂眼缺陷的数据。选取型砂的紧实率、剪切强度、混砂机内旧砂温度、混砂机内旧砂水分、膨润土含量、混配土含量和新砂含量等七个检测频率最高的指标作为主要的参数。训练样本的大小为 $1\ 000 \times 7$, 测试样本的大小为 149×7 。


砂处理过程监测的七个变量记为X1到X7, 对这七个变量进行Jarque-Bera正态分布检验, 可得到第3个到第7个变量检验的P值都满足 $P < 0.005$, 不满足正态分布的假设。因此不能直接使用正态分布的监测方法, 需要有对非高斯分布的处理能力。

使用PCA、KPCA、SVDD、EKPCA-WSVDD四种模型对合力转向桥壳铸件的砂处理过程进行监测。为了图形的表达效果更明显, 将正常样本与异常样本分类集中存放。检测率如表2所示, EKPCA-WSVDD模型表 D_1 控制图异常检出率为91.8%, D_2 控制图异常检出率为49.0%, EKPCA-WSVDD法的监测效果最好。

表2 不同方法的检测率
Table 2 Detection rates of different methods %

	PCA		KPCA		SVDD	EKPCA-WSVDD	
	T^2	SPE	T^2	SPE	D	D_1	D_2
	42.9	38.8	42.9	61.2	73.5	91.8	49.0

PCA监测模型的监测效果如图3所示, PCA模型的 T^2 图、SPE图准确率分别为42.9%和38.8%, 对于第101到第120个异常样本点的检测效果比较好, 对于SPE图和 T^2 图这些数据都在控制限之上, 而后面29个异常样



图3 砂处理过程监测PCA方法的 T^2 和SPE控制图Fig. 3 T^2 and SPE control charts of PCA method for the monitoring of sand treatment process

本点基本都未被检测出来。产生这个现象原因是，这些变量之间的相关关系可能是非线性的，PCA模型没有处理非线性问题的能力； $X_3 \sim X_7$ 的数据都不服从高斯分布，而SPE控制图和 T^2 控制图的99%控制限在计算时是在满足正态分布的前提下，所以总体的监测效果不佳，检测率较低。

KPCA的监测效果如图4所示，KPCA模型的 T^2 图、SPE图准确率分别为42.9%和61.2%，KPCA模型的 T^2 图与PCA模型的 T^2 图异常检出率相同，从图中可以看到两者的数据变化趋势基本保持一致，但是KPCA模型的 T^2

图的监测的异常幅值更大，监测效果更明显。SPE图对于第101到第123个异常样本点的检测效果比较好，第108、109两点没有被检测出来，这个范围内其他数据都在控制限之上，并且后面29个异常样本点也有部分可以被检测出来。相比于PCA的SPE控制图，KPCA的SPE控制图具有更好的监测效果，由于其将输入空间从低维的非线性空间映射到高维的线性空间，在处理非线性过程更具有优势。

EKPCA-WSVDD模型的监测效果如图5所示，其监测效果有了进一步的提高， D_1 控制图和 D_2 控制图的

图4 砂处理过程监测KPCA方法的 T^2 和SPE控制图Fig. 4 T^2 and SPE control charts of KPCA method for the monitoring of sand treatment process图5 砂处理过程监测EKPCA-WSVDD方法的 D_1 和 D_2 控制图Fig. 5 D_1 and D_2 control charts of EKPCA-WSVDD method for the monitoring of sand treatment process

检测率达到91.8%和49.0%。在 D_1 控制图中有6个数据点出现了误报,第108、117、125、126点4个异常数据点没有被检测出来。在 D_2 控制图中没有出现误报的数据点,但第108~110点、第124点、第127~147点这些异常点没有被检测出来。而在SVDD模型的 D 控制图上对于第108点和第124~126点的异常数据检测不出来,因此着重分析第108、125、126这三个异常数据点,这三个异常点如表3所示。

表3 三个典型的未被检出的异常点
Table 3 Three typical undetected outliers

组别	X1	X2	X3	X4	X5	X6	X7
108	41.03	4.92	43.5	1.71	20.8	10.8	33
125	39.8	5.45	43.7	1.71	24.4	12.3	33
126	39.72	5.5	43.7	1.67	20.5	12.1	34

监测点108在 D_1 、 D_2 控制图中都位于控制限之下,表明这7个变量之间的相关关系没有发生变化。采用单变量控制方法分析原因,这7个变量的值均没有超过范围和工艺制定的标准范围,表明数据的均值和方差都在正常的范围内波动。但是这组数据对应的桥壳铸件质量检测时出现了砂眼缺陷,说明第108点的砂处理过程没有发生异常,砂眼缺陷可能是由铸型被破坏、型腔清洁度不够、有落下的散砂等原因造成的,具体原因需要根据工厂实际生产情况联合辅助数据对产生缺陷的原因进行分析。

监测点125和126在 D_1 控制图上位于控制限之下没有被检测出来,而在 D_2 控制图上异常被检测出来。采用单变量控制方法分析原因,第126点的 X_7 超出了企业制定的标准范围,其他6个变量的值均没有超过工艺制定的标准范围,也没有超过范围,表明数据的均值和方差都在正常的范围内波动。而第125点的所有变量均处于正常范围,说明这些变量正常但是变量之间的相关关系发生了变化,因此使用多变量统计过程监测是非常有必要的。

3 结论

针对传统的PCA方法不能处理非线性与非高斯性,对异常情况检测效率低的问题,提出了加权超球核主元分析的生产过程异常检测方法(EKPCA-WSVDD)。首先通过EWMA对数据处理后减小了噪声数据的干扰,增加了检测微小偏移的能力,使用KPCA提取数据在特征空间的非线性特征,并结合加权SVDD方法对非高斯性问题有了较好的处理能力。为保证方法具有良好的效果,选用了合适的核函数以及权重因子、惩罚因子等参数,将 T^2 和SPE统计量转换为与超球体圆心距离的统计量。将建立的EKPCA-WSVDD模型用于TE过程和铸造砂处理过程异常检测,结果表明,与传统的PCA、KPCA、SVDD方法相比,本研究方法的异常检测率更高、监测效果更优。

参考文献:

- [1] 田学森. SPC 统计过程控制在铸造过程质量管理中的应用[J]. 铸造设备与工艺, 2020(3): 53-57.
- [2] 邹卫, 郭之萍, 王宁. 统计过程控制在铸造中的应用[J]. 铸造, 2009(6): 632-634.
- [3] 张爱斌, 向观兵, 田臻, 等. 铸造设备运行过程监测与数据可视化[J]. 铸造, 2019, 68(12): 1402-1406.
- [4] 王武兵. 铸造企业设备数据柔性采集方法及应用[D]. 武汉: 华中科技大学, 2018.
- [5] LOMOV I, LYUBIMOV M, MAKAROV I, et al. Fault detection in tennessee eastman process with temporal deep learning models[J]. Journal of Industrial Information Integration, 2021, 23(1): 100216-100230.
- [6] OSTADSHARIFMEMAR A, AKHAVAN N S T. A review and evaluation of statistical process control methods in monitoring process mean and variance simultaneously[J]. Journal of Optimization in Industrial Engineering, 2010(1): 1-8.
- [7] 赵春晖, 王福利. 工业过程运行状态智能监控: 数据驱动方法[M]. 北京: 化学工业出版社, 2019.
- [8] 李斌锋. 铸造生产中应用多变量统计过程控制的研究[D]. 北京: 清华大学, 2004.
- [9] 郑煜, 张娟. 多变量统计在砂处理过程中的应用[J]. 铸造, 2005(8): 797-799.
- [10] WANG X G, HUANG L W, ZHANG Y W. Modeling and monitoring of nonlinear multi-mode processes based on similarity measure-KPCA[J]. Journal of Central South University, 2017, 24(3): 665-674.
- [11] 李景哲. 基于数据驱动的高含硫天然气净化脱硫过程故障检测与诊断[D]. 重庆: 重庆科技学院, 2015.
- [12] 夏蓓鑫, 简铮, 高雅, 等. 多变量过程监控的D控制图[J]. 华侨大学学报(自然科学版), 2018, 39(6): 920-925.
- [13] 林桐, 陈果, 滕春禹, 等. 基于超球优化支持向量数据描述的滚动轴承故障检测[J]. 振动与冲击, 2019, 38(2): 204-210, 225.
- [14] 冉一然. 基于PCA-SVDD的故障检测研究与应用[D]. 重庆: 西南大学, 2020.

- [15] ALAM S, KWON G R. Alzheimer disease classification using KPCA, LDA, and multi-kernel learning SVM [J]. *International Journal of Imaging Systems & Technology*, 2017, 27 (2) : 133–143.
- [16] 张少捷, 王振雷, 钱锋. 基于LTSA的FS-SVDD方法及其在化工过程监控中的应用 [J]. *化工学报*, 2010, 61 (8) : 1894–1900.
- [17] NISHIMURA K, MATSUURA S, SUZUKI H. Multivariate EWMA control chart based on a variable selection using AIC for multivariate statistical process monitoring [J]. *Statistics & Probability Letters*, 2015, 104: 7–13
- [18] LEE K Y, KIM D W, LEE K H, et al. Density-induced support vector data description [J]. *IEEE Transactions on Neural Networks*, 2007, 18 (1) : 284–289
- [19] 韩贵金. 加权SVDD算法在人体姿态估计中的研究与应用 [J]. *计算机工程与应用*, 2017, 53 (15) : 132–136.
- [20] SHEN Y, DING S X, HAGHANI A, et al. A comparison study of basic data-driven fault diagnosis and process monitoring methods on the benchmark Tennessee Eastman process [J]. *Journal of Process Control*, 2012, 22 (9) : 1567–1581.
- [21] 龙威. 粘土砂有效膨润土自动测定方法及质量控制系统研究 [D]. 武汉: 华中科技大学, 2010.

Weighted Hyperspherical Kernel Principal Component Analysis for Anomaly Detection in Casting Production Process

XIANG Guan-bing, LIU Ying-hui, JI Xiao-yuan, YIN Ya-jun, ZHOU Jian-xin

(State Key Laboratory of Materials Processing and Die & Mould Technology, Huazhong University of Science & Technology, Wuhan 430074, Hubei, China)

Abstract:

The casting production process data have the characteristics of high dimension, nonlinearity and non Gauss, which leads to the problems of easy omission and low detection efficiency in the principal component analysis method. Therefore, a production process anomaly detection method based on weighted hypersphere kernel principal component analysis was proposed in this paper. Firstly, the exponential weighted moving average was used to smooth the data, and then the kernel principal component analysis method was used to map the data to obtain the principal component space and residual space. Finally, the information of the two subspaces was input into the sample weighted support vector data description to establish the statistical model, and the established model was used to detect the anomaly of the data. Tennessee Eastman process data and cast sand treatment process data were used for verification. The results showed that this method had higher detection rate than principal component analysis.

Key words:

casting; anomaly detection; principal component analysis; support vector data description; sand treatment