

故障检测中核参数优化方法性能评估

张 凯^{1,2}, 齐恬婧¹, 彭开香^{1,2†}, 储若慧¹

(1. 北京科技大学 自动化学院, 北京 100083; 2. 工业过程知识自动化教育部重点实验室, 北京 100083)

摘要: 近年来, 基于核主元分析与核偏最小二乘的方法经常被应用于过程监控与故障检测领域以克服工业过程的非线性. 研究发现此类方法的检测性能很大程度上受核参数的影响, 而目前学术界对该参数的优化方法研究较少. 因此, 本文以最常用的高斯核方法为例, 首先总结了3类常用的核参数优化方法: 二分法、基于BP神经网络的重构法和基于样本分类的重构法; 其次重点分析每个方法的特点和它们之间的联系, 并评估它们的性能; 最后将上述方法设计成一个核参数优化系统应用于热连轧过程的故障检测中. 应用结果表明, 优化后的核参数能显著提高故障检测性能.

关键词: 故障检测; 过程监控; 核参数优化; 核主元分析; 核偏最小二乘; 热连轧

引用格式: 张凯, 齐恬婧, 彭开香, 等. 故障检测中核参数优化方法性能评估. 控制理论与应用, 2019, 36(9): 1520 – 1527

DOI: 10.7641/CTA.2019.80497

Performance evaluation for kernel parameter optimizations in fault detection methods

ZHANG Kai^{1,2}, QI Tian-jing¹, PENG Kai-xiang^{1,2†}, CHU Ruo-hui¹

(1. School of Automation Electronic Engineering, University of Science and Technology Beijing, Beijing 100083, China;

2. Key Laboratory of Knowledge Automation for Industrial Processes of Ministry of Education, Beijing 100083, China)

Abstract: In recent years, kernel principal component analysis and kernel partial least squares-based methods have been widely applied to the process monitoring and fault detection (PM-FD) field to address the nonlinearity in complex industrial processes. It has been found that the performance of these fault detection methods can be significantly affected by the kernel parameter, however, few researches have been focused on this area. Motivated by these observations, on the basis of the commonly used Gaussian kernel, this paper firstly revisits three types of kernel parameter optimization methods, namely, the dichotomy-based, back propagation (BP) neural network reconstruction-based and sample classification reconstruction-based methods. Then, their individual characteristics, interconnections, and performance are analyzed in-depth. Finally, above parameter optimization methods are integrated into a kernel parameter optimization system and applied to the PM-FD in a hot strip rolling process. Compared with selecting parameter empirically, the experiment results shows that the optimized kernel parameter can improve the PM-FD performance.

Key words: fault detection; process monitoring; kernel parameter optimization; kernel principal component analysis; kernel partial least squares; hot strip mill

Citation: ZHANG Kai, QI Tianjing, PENG Kaixiang, et al. Performance evaluation for kernel parameter optimizations in fault detection methods. *Control Theory & Applications*, 2019, 36(9): 1520 – 1527

1 引言

现代制造技术的不断发展和自动化水平的提高使得自动化装置的功能日趋完善, 但其结构复杂程度、集成化程度也日趋增高, 正所谓“牵一发而动全身”, 微小故障很有可能导致整个系统被破坏, 造成巨大的

经济损失甚至是人员的伤亡. 因此, 保障系统安全、可靠、稳定的运行具有重要意义^[1-2]. 故障检测作为提高系统可靠性与安全性的关键技术, 成为了当今国内外过程控制领域的热点研究方向, 在航空发动机、雷达、高铁列车、自主机器人等系统中起到了提高系统使用

收稿日期: 2018-07-06; 录用日期: 2019-01-21.

†通信作者. E-mail: kaixiang@ustb.edu.cn; Tel.: +86 10-62333084.

本文责任编辑: 张化光.

国家重点研发计划项目(2017YFB0306403), 国家自然科学基金项目(61703036, 61773053), 中央高校基本科研业务费项目(FRF-TP-17-042A1), 鞍山钢铁集团数据项目资助.

Supported by the National Key R&D Program of China (2017YFB0306403), the National Natural Science Foundation of China (61703036, 61773053), the Fundamental Research Funds for the Central Universities (FRF-TP-17-042A1) and the Ansteel Group Corporation.

寿命、保障系统正常运行、降低维护成本等关键作用^[3-8]。

随着信息化与工业化深度融合的推进, 促进我国智能制造战略、工业现代化转型已得到了政府的高度重视和大力支持, 保障工业过程安全可靠运行这一要求使故障检测技术在工业领域取得了长足的发展。现有的工业过程故障检测方法可分为基于解析模型、基于知识以及基于数据的方法。传感器、计算机、通信、物联网、数据存储等技术使工业生产过程中产生并存储了大量的数据, 推进了基于数据的故障检测理论方法的研究与应用实践^[9]。其中研究和应用最多的是以主成分分析 (principal component analysis, PCA)、偏最小二乘 (partial least squares, PLS) 和独立成分分析 (independent component analysis, ICA) 等方法为核心的多元统计方法, 这类方法强调过程变量间、过程变量与质量变量(或其他关键性能指标)间的潜结构, 在使用过程正常运行数据建立潜结构模型的基础上定义故障检测指标及其控制限进行故障检测^[10]。然而当过程的非线性较强时, 用传统的PCA, PLS等模型进行故障检测容易导致故障的错报和漏报。

针对复杂工业过程的非线性问题, Schölkopf等人于1998年提出的核主成分分析(kernel principal component analysis, KPCA)^[11]被引入到了故障检测领域中。即先通过非线性映射将原始数据映射到高维特征空间, 再在高维空间中建立PCA模型进行故障检测。核函数的引入能有效地捕捉训练数据的非线性特征并解决建模过程中过拟合和欠拟合的问题, 被广泛应用于非线性过程的故障检测中。这类基于核的故障检测方法中最典型是基于KPCA^[12]以及核偏最小二乘(kernel partial least squares, KPLS)^[13]的故障检测方法, 最常用到的核函数是高斯核函数。当核函数中的高斯核参数选取不合适时, 上述方法难以得到良好的故障检测结果。目前学术界对该参数的优化方法研究较少, 只针对具体的故障检测方法提出了几种优化核参数的手段, 如基于反向传输(back propagation, BP)神经网络的重构法^[14]、基于样本分类的重构法^[15]等。但由于缺乏对相关方法的系统分析对比, 导致初学者和现场工程师在确定核参数时因对核参数作用及相关优化方法的系统性认知不足而过于依赖前人的经验, 一方面增大了确定核参数的难度和工作量, 另一方面影响了故障检测的性能。因此通过一个有效的工具对已知核参数优化方法进行类比和评估, 并对指定工业过程确定一个能保障检测性能的核参数是十分必要的。

与常规工业生产过程相比, 带钢热连轧过程的特性更为复杂, 精轧时整个板带需通过如图1所示的7个

机架, 整体轧制环境十分复杂, 产品质量更易受到环境、原材料、设备状况等因素的影响^[16]。在工业现场对热连轧过程的精轧机组进行过程监控时, 机架内的底层传感装置将过程运行数据传入PLC, PLC将实时的过程数据和对精轧机组的控制作用传入光纤连接的高速环网, 过程监控单元将对这些高速的过程数据进行实时故障检测, 以保障整个轧钢系统的安全稳定运行, 历史数据会通过低速以太网传输至历史数据库。在过程监控单元中, 由于带钢热连轧过程具有很强的非线性, KPCA, KPLS等非线性故障检测方法逐渐取代了传统方法。但其中的核参数对检测结果具有重要的影响, 因此为了获得更好的故障检测模型、提高对热连轧过程的检测性能, 利用过程的历史数据库建立图1中的核参数优化系统, 为在线监控提供优化后的核参数、主元个数甚至故障检测方法是十分必要的。

针对上述问题, 本文对3种核参数优化方法: 二乘法、基于BP神经网络的重构法和基于样本分类的重构法进行了分析对比并将它们用于优化带钢热连轧过程监控中的核参数, 以期实现: 1) 总结各核参数优化方法的特点, 为初学者和现场工程师给予核参数优化上的理论指导; 2) 设计基于KPCA, KPLS的核参数优化系统, 实现从理论成果到实践的转化; 3) 将设计的核参数优化系统应用于热连轧过程的监控中以提高故障检测的性能并对理论分析成果进行验证。

2 研究与应用背景

作为典型的复杂工业过程, 带钢热连轧过程有严重的非线性, 用传统数据驱动监控方法容易导致故障的错报和漏报。因此非线性的故障检测方法更适用于热连轧过程的监控。在非线性方法中, 由于核学习方法具有结构风险最小化的理论基础, 能有效捕捉训练数据的非线性特征且使用灵活, 在热连轧过程的实时监测中得到了良好应用。但其中的核参数优化问题没有统一的理论指导, 限制了非线性过程故障检测方法的性能。

2.1 基于核学习的非线性故障检测

图1中建立非线性故障检测模型的方法中最常用的就是KPCA和KPLS。给定过程的输入、输出变量矩阵为

$$X \in \mathbb{R}^{n \times p} = [x_1 \ x_2 \ \cdots \ x_n]^T$$

和

$$Y \in \mathbb{R}^{n \times m} = [y_1 \ y_2 \ \cdots \ y_n]^T,$$

分别有 m 个过程变量和 p 个质量变量。非线性映射函数 φ 将原始输入中 X 从原始空间映射到高维特征空间 F , 映射后输入过程变量变为

$$\Phi = [\varphi(x_1) \ \varphi(x_2) \ \cdots \ \varphi(x_n)]^T \in \mathbb{R}^{n \times M}.$$




图1 7机架热连轧工业过程示意图

Fig. 1 A schematic of a 7-stand hot strip mill industrial process

KPCA, KPLS方法对上述过程故障检测的实现过程如下:

1) 计算核矩阵. 为避免计算映射函数 φ , 首先定义核矩阵 $K \in \mathbb{R}^{n \times n}$ 表示 $\Phi \Phi^T$, 其中 $K_{ij} = \mathcal{K}(x_i, x_j) = \langle \varphi(x_i), \varphi(x_j) \rangle$, $i, j = 1, 2, \dots, n$.

对原始映射核矩阵 K_{raw} 进行归一化处理:

$$K = (I_n - \frac{1}{n} \mathbf{1}_n \mathbf{1}_n^T) K_{\text{raw}} (I_n - \frac{1}{n} \mathbf{1}_n \mathbf{1}_n^T), \quad (1)$$

其中 $\mathbf{1}_n$ 为元素全为1的 n 维列向量.

2) 计算得分矩阵. KPCA, KPLS计算得分矩阵 $T \in \mathbb{R}^{n \times A}$ 的方式是不同的:

KPCA中 $T = K A$, 其中 $A = [\alpha_1 \dots \alpha_A]$ 是特征方程 $\lambda \alpha = (1/(n-1)) K \alpha$ 的前 A 个最大特征值对应的特征向量, 且 α 通过标准化应满足 $\|\alpha\|^2 = (1/(n-1)) \lambda$.

KPLS在高维的特征空间 F 上建立和PLS一样的线性模型, 即顺序的按照 Φ 和 Y 的相关性从两矩阵中抽取潜变量 t, u 和权重向量 w, q . 可分别得到 Φ 和 Y 的得分矩阵 $T = [t_1 \ t_2 \ \dots \ t_A] \in \mathbb{R}^{n \times A}$, $U = [u_1 \ u_2 \ \dots \ u_A] \in \mathbb{R}^{n \times A}$.

3) 计算新采样对应的得分向量. 新测试样本 $x_{\text{new}} \in \mathbb{R}^m$ 的原始核向量为 $(K_{\text{raw}}^{\text{new}})_i = \mathcal{K}(x_i, x_{\text{new}})$. 归一化后为

$$K_{\text{new}} = (I_n - \frac{1}{n} \mathbf{1}_n \mathbf{1}_n^T) (K_{\text{raw}}^{\text{new}} - \frac{1}{n} K_{\text{raw}} \mathbf{1}_n). \quad (2)$$

KPCA, KPLS方法计算其得分向量分别为

$$\begin{cases} t_{\text{new}, \text{KPCA}} = W^T \varphi(x_{\text{new}}) = A^T K_{\text{new}}, \\ t_{\text{new}, \text{KPLS}} = (U^T K T)^{-1} U^T K_{\text{new}}. \end{cases} \quad (3)$$

4) 计算新采样的 T^2 统计量、SPE统计量. 使用 T^2 统计量和SPE统计量分别检测数据在主元空间和残差空间的变化^[17]. KPCA, KPLS故障检测中 T^2 统计量表达式均为 $T^2 = t_{\text{new}}^T \Lambda^{-1} t_{\text{new}}$, 但 Λ 的含义不同, 其中:

$$\begin{cases} \Lambda_{\text{KPCA}} = \text{diag}\{\lambda_1, \dots, \lambda_A\}, \\ \Lambda_{\text{KPLS}} = (1/(n-1)) T^T T. \end{cases} \quad (4)$$

两种检测方法的SPE统计量表达式为

$$\begin{cases} \text{SPE}_{\text{KPCA}} = \mathcal{K}(x_{\text{new}}, x_{\text{new}}) - t_{\text{new}}^T t_{\text{new}}, \\ \text{SPE}_{\text{KPLS}} = \varphi^T(x_{\text{new}}) \varphi^T(x_{\text{new}}) - \\ 2 t_{\text{new}}^T T^T K_{\text{new}} + t_{\text{new}}^T T^T K T t_{\text{new}}, \end{cases} \quad (5)$$

其中

$$\begin{aligned} \varphi^T(x_{\text{new}}) \varphi^T(x_{\text{new}}) = \\ 1 - \frac{2}{n} \sum_{i=1}^n K_{\text{raw}}^{\text{new}}(i) + \frac{1}{n^2} \sum_{i=1}^n \sum_{j=1}^n K_{\text{raw}}(i, j). \end{aligned} \quad (6)$$

5) 计算控制限. T^2 统计量、SPE统计量对应的控制限如式(7)所示:

$$\begin{cases} T_a^2 = \frac{A(n^2 - 1)}{n(n - A)} F_{A, n-A; a}, \\ \text{SPE}_a = g \chi_h^2, \end{cases} \quad (7)$$

其中: $F_{A, n-A; a}$ 是带有 A 和 $n - A$ 个自由度、置信水平为 a 的 F 分布临界值; $g \chi_h^2$ 为比例因子为 g 、自由度为 h 的 χ^2 分布, 且 $g = S/2\mu$, $h = 2\mu^2/S$; μ, S 分别为训练样本的SPE统计量的均值和方差. 当样本统计量对应的统计值大于该统计量的控制限时, 则认为该时刻系统被检测出故障.

2.2 核参数优化的重要性

从上述基于核方法的过程监控中看出第1步都是选择核函数计算核矩阵 K . 虽然核函数不是唯一的, 但它的选择也不是任意的^[18]. 核函数的计算量与特征空间维数无关且不同的核函数确定了不同的非线性变换函数. 目前使用最广泛的核函数为高斯核函数, 其表达式为

$$\mathcal{K}(x_i, x_j) = \exp(-\frac{\|x_i - x_j\|^2}{c}), \quad (8)$$

其中: x_i, x_j 分别表示两个不同的样本向量, 核参数 c 表示高斯函数的宽度. c 的大小会影响检测模型的鲁

棒性和敏感性, 从而影响故障检测率 (fault detection rate, FDR) 和误报率 (false alarm rate, FAR), 因此 KPCA, KPLS 等方法使用高斯核函数进行非线性映射时都需要重点考虑核参数 c 的大小.

从高斯核函数的表达式分析, 考虑以下两种极限情况:

$$1) \text{ 当核参数 } c \rightarrow \infty \text{ 时, } \frac{\|x_i - x_j\|^2}{c} \rightarrow 0.$$

即正常样本与正常样本、故障样本的间距会被缩放至很小, 在一定程度上模糊正常与故障样本之间的差异, 导致故障样本被错认为正常样本, 引起漏报.

$$2) \text{ 当核参数 } c \rightarrow 0 \text{ 时, } \frac{\|x_i - x_j\|^2}{c} \rightarrow \infty.$$

即正常样本与正常样本、故障样本的间距会被放大. 虽然正常与故障样本之间的差异也会被放大, 但正常样本之间的距离过大可能导致正常样本被错认为故障样本, 导致误报.

因此, 在对热连轧过程基于 KPCA, KPLS 的故障检测方法中进行核参数优化即根据图1所示的历史数据库在建立非线性故障检测模型时考虑一个合适的系数来缩放样本间的差异, 使实时检测时故障样本能被检测出来并保证正常样本不被误检.

3 核参数优化方法性能评估

为了提高带钢热连轧过程基于 KPCA, KPLS 方法的监控性能, 对其进行核参数优化是必要的. 而相关方法缺乏分析对比, 应用时增大了确定核参数的难度和工作量, 使得在很多场合仍是依靠经验或试凑的方法选取 c 的. 本文将对比分析3种核参数优化方法并评估它们的性能.

3.1 方法分类

本文介绍的核参数优化方法有: 二分法^[19]、基于 BP 神经网络的重构法(以下简称 BP 网络法)、基于样本分类的重构法(以下简称样本分类法)并对它们进行性能评估.

3.1.1 二分法

虽然 FAR, FDR 随 c 的变化难以用具体的表达式确定, 但这个变化规律在文献[19]中已有具体的描述. 二分法根据这一规律通过优化核参数调整控制限, 使 FAR, FDR 指标满足设定的要求, 获得更好的故障检测性能. 该方法首先应将正常数据分为训练、测试两部分, 选择 c 的候选范围 $[c_{\min}, c_{\max}]$, 并确定可接受的测试样本 FAR 范围 $\Omega = [\text{FAR}_{\min}, \text{FAR}_{\max}]$ (本文取 4% ~ 8%) 作为基准. 接着以 $c_{\min}$ 和 $c_{\max}$ 为高低限执行二分法, 直到找到 c 能够使测试样本的 FAR 落在范围 Ω 内. 但 FAR 随 c 的变化规律不是线性的, 在二分法的过程中存在上下限对应的 FAR 在 Ω 同侧的情况, 此时若没有人为指导调整上下限, 二分法将无法继续运行.

3.1.2 BP 网络法

对于一个特定的数据集 X 执行具有不同核参数的 KPCA, KPLS 就会得到不同的得分矩阵 T (其每一列代表一个得分向量). 较好的 c 对应的得分矩阵 T 中能包含更多原始数据集 X 的信息. BP 网络法构建了具体的指标衡量得分矩阵 T 描述原始数据集 X 的程度. 分别将原始数据集 X 及对应的得分矩阵 T 划分为 $[X_{\text{tr}}; X_{\text{te}}]$ 和 $[T_{\text{tr}}; T_{\text{te}}]$, 使用训练部分的得分向量 T_{tr} 为输入、样本向量 X_{tr} 为输出训练人工神经网络 (artificial neural network, ANN), 原始数据和高维空间数据中的对应关系就被存在了训练好的 ANN 中^[20]. 接着以 T_{te} 为 ANN 的输入, 其理想输出即为测试部分的样本向量 X_{te} , 实际输出为对样本向量测试部分的估计 $\hat{X}_{\text{te}}$, 用其代表 ANN 对原始样本向量 X_{te} 的重构. 定义相对重构误差 (relative reconstruction error, RRE) 定量描述重构误差的大小, 如式(9)所示:

$$\text{RRE} = \frac{\|X_{\text{te}} - \hat{X}_{\text{te}}\|^2}{\|X_{\text{te}}\|^2}. \quad (9)$$

对于一个确定的过程在使用 KPCA, KPLS 建立模型的时候, RRE 就可以看作是 c 的函数, 记为 $\text{RRE}(c)$. 用 Δ_c 表示核参数候选集, c_{opt} 表示最优的核参数, 其大小为

$$c_{\text{opt}} = \arg \min_{c \in \Delta_c} \text{RRE}(c), \quad (10)$$

即认为令相对重构误差 RRE 取最小的 c 为最优核参数, 具有更好的故障检测性能. 该方法能够通过扩展式(10)得到式(11)同时选出 c 和主元个数 A :

$$(c_{\text{opt}}, A) = \arg \min_{c \in \Delta_c, A \in \Delta_A} \text{RRE}(c, A), \quad (11)$$

其中 Δ_A 为 A 的候选集.

3.1.3 样本分类法

基于核的故障检测方法在由核函数映射成的特征空间中构建子空间, 并使正常样本位于该子空间内或附近, 而异常样本远离该子空间, c 不同时样本在特征空间中的间距也有所差异. 从优化核参数的角度来看, 合适的核参数应使相应的模型能够区分正常样本与故障样本之间重构误差 (reconstruction error, RE) 的差异, 保障故障检测的性能. 式(12)中定义的 RE 指标是从样本映射到子空间距离的测量, 显然故障样本的 RE 大于正常样本.

$$\begin{aligned} \text{RE}(x_i) &= \|\varphi(x_i) - Wt(x_i)\|^2 = \\ &= \mathcal{K}(x_i, x_i) - \frac{2}{n} k_i^T \mathbf{1}_n - \frac{1}{n^2} \mathbf{1}_n^T K \mathbf{1}_n - \|t(x_i)\|^2, \end{aligned} \quad (12)$$

其中 W 为特征向量矩阵. 然而故障检测的训练集中没有故障样本, 因此 Xiao Y 等人在文献[15]中改进了边

界模式选择法(border-edge pattern selection method, BEPS)^[21]对训练样本进行划分,用内部样本代替正常样本、边缘样本代替故障样本。当核参数合适时,模型应使内部样本的RE小于边缘样本的RE,其实质是模型能有效辨别正常样本与故障样本的差异。因此,该规则将被用来进行核参数优化。

基于以上分析,使用样本分类法进行核参数优化时选取目标函数如式(13)所示:

$$f_{A,c} = \frac{\min_{x_i \in X_{ED}} \{RE(x_i)\} - \min_{x_i \in X_{IN}} \{RE(x_i)\}}{\text{std}(RE(X_{IN}))}. \quad (13)$$

在该目标函数中, X_{ED} 和 X_{IN} 分别表示边缘样本集和内部样本集。 $\text{std}\{RE(X_{IN})\}$ 为内部样本集RE的标准差。目标函数取最大值时对应的 c 和 A 可以在训练集上建立合适的模型,得到更好的故障检测结果。

3.2 性能评估

本文从检测性能、计算量、干扰项及内在联系4个方面对3种核参数优化方法进行性能评估。

3.2.1 检测性能

从优化核参数所用的指标分析,3种方法的检测性能应该满足:二分法受本文 $\Omega = 4 \sim 8\%$ 的作用,检测结果会出现一定误检,但能保证高FDR;BP网络法具有比较综合的检测结果,兼顾FAR, FDR两指标,从总体上提高检测性能;样本分类法应有非常高的FDR,但却无法保证低FAR。

3.2.2 计算量

3种方法的计算时间从大到小依次为BP网络法、样本分类法、二分法。BP网络法花费了大量时间进行神经网络的训练。尤其在将该方法用于优化KPLS模型的 c 时,若 c 和 A 的候选个数分别为 m 和 n ,则需要训练 $m \times n$ 个神经网络。且候选集每增加一个元素,训练的神经网络个数就增加多个,计算量非常大。应用该方法时可通过减小训练次数、牺牲网络训练精度或减少核参数候选个数减少计算量。而样本分类法的计算量主要集中在样本分类上,尤其是分类后还需返回标签,并在两个样本范围内分别求指标RE的最小值,因此计算时间较长。二分法能大幅度缩小核参数候选范围,因此计算量非常小。但若出现新的核参数上下限对应的FAR在 Ω 同侧的情况,就需要人为参与修改,此时就会增加计算耗时。

3.2.3 干扰项

3种方法的干扰项从多到少依次为BP网络法、样本分类法、二分法。BP网络中隐藏层输出层的传递函数、各层神经元个数、训练精度、训练次数等参数都影响神经网络的拟合性能从而对核参数优化指标RRE造成影响,而且神经网络在迭代过程若是陷入局

部极小点,不仅会导致无法计算出正确的RRE(c),还会增大训练时长,因此神经网络法干扰项最多。样本分类法用到了3个参数:最近邻个数 b 、内部样本选择阈值 η 和边缘样本选择阈值 γ 对样本进行划分。虽然它们的取值对选出最具代表性的内部样本影响不大,但会影响边缘样本和故障样本的相近程度从而影响模型正确辨别正常样本与故障样本的能力。此外,这3个参数的取值还决定了目标函数中边缘样本和内部样本的数据集合大小,影响该方法的计算量。因此这3个参数即为样本分类法中的干扰。二分法中,由于FAR随 c 的变化规律无法用具体表达式确定且这一变化并非线性的,因此二分法中存在新的 $c_{\min}$, $c_{\max}$ 对应的FAR在 Ω 同侧的情况,此时需要人为调整上下限该方法才能继续进行,这一调整受人主观影响,即为二分法的干扰。

3.2.4 内在联系

通过对3种非线性故障检测中的核参数优化方法的对比分析,可将它们分为两类:

1) 模型层面的优化方法。

模型层面的优化即从算法模型本身的性能出发建立目标函数对核参数进行优化。如KPCA算法的目标是提取原始数据中的主成分以降维,那么模型层面的优化目标即为寻找能使KPCA模型更好描述原始数据的核参数。这类优化方法因为不涉及模型的具体应用,因此可被扩展到KPCA算法在故障检测领域外的核参数优化中。

2) 应用层面的优化方法。

应用层面的优化则更侧重于从算法的应用结果出发建立目标函数进行核参数优化。如将KPCA, KPLS等模型用于故障检测时,构建与故障检测结果直接相关的目标函数进行核参数优化即为应用层面的优化方法。这类优化方法主要考虑的是检测结果,因此可被扩展到其他基于核方法的故障检测模型的核参数优化中。

按上述分类原则,BP网络法属于模型层面的优化方法,二分法和样本分类法为应用层面的优化方法。事实上二分法和样本分类法优化 c 都是利用训练数据调整控制限的过程,二者的区别在于二分法通过调整 c 来调整训练数据的统计值和控制限将测试集中出现误警的样本个数控制在 Ω 内,它是通过全部的训练样本调整故障检测控制限的;而样本分类法中边缘样本是训练数据中最容易出现误警的样本,内部样本则是几乎不会出现误报的样本,该方法相当于先对训练样本进行筛选得到内部样本和边缘样本和它们分别对应的控制限,通过调整 c 使两条控制限的间距最大进行核参数优化。

故障检测中指标FAR与FDR难以兼顾, 可根据实际控制需求选择适宜的核参数优化方法. 样本分类法能够同时选择 c 和 A 并保证高FDR. 二分法可以通过调整 Ω 决定经其优化后的 c 更倾向于高FDR还是低FAR. Ω 小, 优化后的 c 倾向于低FAR; Ω 大, 优化后的 c 倾向于高FDR. 但该方法虽然计算量小但可能需要人为指导. BP网络法虽然能同时选择 c 和 A , 但其计算成本大且干扰较多. 因此, 优化核参数时需考虑故障检测的性能要求、计算能力以及是否能人为参与来选择适宜的方法.

4 带钢热连轧过程应用

4.1 过程描述

一条典型的带钢热连轧机生产线主要由加热炉、粗轧机、中间延时辊道、飞剪、精轧机组、热输出辊道及层流冷却和卷取机组成. 加热炉保证板带钢材以 1200°C 进入粗轧机, 在粗轧机组板坯被制成 $28\sim 45\text{ mm}$ 厚的中间坯, 在宽度变化不大的条件下板坯沿长度方向能够得到有效延伸. 板坯经由热输出辊道从粗轧区进入精轧机组进行7个机架(F1-F7)的连续轧制. 精轧完成的带钢经层流冷却系统降温后卷曲为成品钢卷.

精轧机组是带钢热连轧机的核心装备, 成品带钢的尺寸精度、组织性能和表面质量基本上在精轧形成. 如图1所示, 精轧机组一般由7个机架组成, 且各机架不是独立的, 而是使用各种控制方法连接在一起. 在每个支架中都配备了液压系统以提供所需的滚动和弯曲力来控制辊缝, 从而保证带钢经该机架轧制后得到相应出口厚度的带钢; 还放置了机电系统来旋转辊子, 使钢带能够向前移动. 滚动和弯曲力可以分别通过压磁和量程传感器实时测量, 但由于高速和高温, 两个支架之间的厚度通常不可测. 因此对精轧机组的运行状态进行实时监测是必要的.

4.2 故障描述

以鞍钢1700 mm带钢热连轧生产线为研究对象, 以0.05 s为采样间隔分别采集厚度为2.70 mm和3.95 mm的现场数据进行建模并对其故障进行实时检测. 选取7个机架的辊缝、轧制力和弯辊力(第1机架无弯辊)共20个过程变量, 质量变量选为第7机架出口带钢厚度.

本文考虑精轧机组的3种常见故障, 如表1所示. 故障1是由于第5机架弯辊系统的油压传感器故障导致弯辊力采样值出现阶跃型故障, 该故障影响出口带钢板形, 但对厚度影响很小; 故障2为第4机架液压压下辊缝控制系统回路故障, 使第4机架液压压力减小, 导致第4机架辊缝故障, 影响最终成品厚度; 故障3为第2, 3机架间冷却水调节阀不能按照设定关闭, 使第3机架入口带钢温度偏低, 最终导致该机架的出口带钢厚度产生正向偏差^[22].

表1 热连轧过程故障信息

Table 1 Hot strip mill process fault information

编号	故障描述	发生时间/s
1	第5机架弯辊力控制系统故障	10
2	第4机架液压压下系统执行器故障	20
3	第2, 3机架间冷却水调节阀故障	10

4.3 应用结果及分析

按照上节描述的过程变量与质量变量从热连轧现场分别采集规格2.70 mm规格过程数据3组、3.95 mm规格过程数据6组, 分别作为故障2、故障1、故障3的历史正常数据、历史故障数据和实时故障发生数据. 历史数据库由历史正常数据和历史故障数据组成. 使用本文介绍的3种基于KPCA, KPLS故障检测模型的核参数优化方法设计一个热连轧过程的非线性故障检测核参数优化系统, 如图2所示. 利用历史数据库中的正常数据优化KPCA, KPLS中的 c , 并通过库中的故障数据测试优化后 c 的检测性能, 将测试后的 c 用于对实时数据的过程监控. 经核参数优化系统优化后的 c 对实时数据的检测结果表明:

1) 3种故障获得最优检测结果的方法分别是基于BP网络法的KPCA检测、基于样本重构法的KPCA检测和基于二分法的KPLS检测, 对应的 T^2 统计量检测结果如图3-5所示(将控制限记为 J_{th}). 不同的过程数据对应的最优核参数优化方法不同, 可通过历史故障数据对优化后的 c 进行测试, 将测试结果更理想的 c 应用于现场实时故障检测. 与优化后的 c 相比, 将KPCA, KPLS中 c 的经验取值应用于热连轧过程的故障检测不能得到好的结果.

2) 3种核参数优化方法在Intel i7-7700HQ 4核2.8 GHz CPU的PC机上计算用时如图6所示. 图中BP网络法的计算时长对应的训练次数和网络训练精度分别为100和0.0001, 将该方法用于同时选择KPLS模型的 c 和 A 时比只选择KPCA模型的 c 多用了近6000 s, 而样本重构法仅多用了300 s就完成了这一选择. 可见计算时间过长是BP网络法的显著缺点. 二分法的计算时间没有考虑人为调整二分上下限的时间, 二分法的真正用时应比图6要长.

3) 经不同方法优化后对3种故障的平均检测结果如表2所示. 正如上节分析的一样, 样本分类法充分保证了检测结果具有高FDR, 平均FDR达到了100%, 但其FAR也是最高的; 二分法的 Ω 取为4%~8%, 得到了居中的检测结果, 适当提高FDR的同时也保证了较低的FAR; BP网络法作为能同时选择 c 和 A 的优化方法, 在KPCA的应用中得到了较高的FDR、在KPLS的应用中得到了较低的FAR, 提高了故障检测性能. 但因该方法优化指标与故障检测没有直接联系, 因此无法确定该方法是针对指标FAR还是FDR来改善性能的.




图2 基于热连轧历史数据库的核参数优化系统

Fig. 2 Kernel parameter optimization system based on the hot strip mill process history database




图3 故障1的检测结果

Fig. 3 Detection result of fault 1




图4 故障2的检测结果

Fig. 4 Detection result of fault 2




图5 故障3的检测结果

Fig. 5 Detection result of fault 3




图6 各方法的计算时长

Fig. 6 Calculation time of each method

5 结论

针对目前复杂工业过程基于核的非线性故障检测中核参数难以确定且选取工作量大这一现状, 本文对3种核参数优化方法进行分析对比并设计了一个基于

KPCA, KPLS模型的核参数优化系统应用于热连轧过程的故障检测,一方面给出了各种核参数优化方法的特点及性能评估,为初学者和实际应用者提供了核参数优化上的理论指导和建议;另一方面设计的核参数优化系统有效地提高了带钢热连轧过程的故障检测性能并验证了理论分析成果.事实上故障检测领域还有许多基于核思想的非线性方法,例如支持向量机(support vector machine, SVM)^[23]、支持向量数据描述(support vector data description, SVDD)^[24]等.作者的后续工作将继续关注核参数优化在此类方法中的应用并考虑引入故障信息对核参数进行选取.

表2 核参数优化后的故障检测结果

Table 2 Fault detection results after optimization of kernel parameters

优化方法	故障检测方法	FAR/%	FDR/%
经验值	KPCA	6.92	2.92
	KPLS	8.88	33.34
二分法	KPCA	12.67	83.25
	KPLS	14.50	83.34
BP网络法	KPCA	16.00	85.92
	KPLS	10.96	71.34
样本重构法	KPCA	16.16	100.00
	KPLS	16.38	100.00

参考文献:

- [1] ZHANG Ke, ZHOU Donghua, CHAI Yi. Review of multiple fault diagnosis methods. *Control Theory & Applications*, 2015, 32(9): 1143 – 1157.
(张可, 周东华, 柴毅. 复合故障诊断技术综述. 控制理论与应用, 2015, 32(9): 1143 – 1157.)
- [2] WANG Fuli, CHANG Yuqing, WANG Shu. *Multimodal Complex Industrial Process Monitoring and Fault Diagnosis*. Beijing: Science Press, 2016.
(王福利, 常玉清, 王姝. 多模态复杂工业过程监测及故障诊断. 北京: 科学出版社, 2016.)
- [3] LIN T, CHEN G, OUYANG W, et al. Hyper-spherical distance discrimination: a novel data description method for aero-engine rolling bearing fault detection. *Mechanical Systems and Signal Processing*, 2018, 109: 330 – 351.
- [4] LI D, JI D, LIU J, et al. A multi-model EKF integrated navigation algorithm for deep water AUV. *International Journal of Advanced Robotic Systems*, 2016, 13(1): 1 – 15.
- [5] ZHANG L, CHEN M, WANG X, et al. TOA estimation of chirp signal in dense multipath environment for low-cost acoustic ranging. *IEEE Transactions on Instrumentation and Measurement*, 2019, 68(2): 355 – 367.
- [6] WANG N, SUN J, ER M J. Tracking-error-based universal adaptive fuzzy control for output tracking of nonlinear systems with completely unknown dynamics. *IEEE Transactions on Fuzzy Systems*, 2018, 26(2): 869 – 883.
- [7] ZHU J, JI D, XU Z, et al. Combined optimisation of waveform and quantisation thresholds for multistatic radar systems. *IET Signal Processing*, 2018, 12(5): 559 – 565.
- [8] ZHU D, LIU Y, SUN B. Task assignment and path planning of a multi-AUV system based on a gladius bio-inspired self-organising map algorithm. *Journal of Navigation*, 2017, 71(2): 1 – 15.
- [9] PENG Kaixiang, MA Liang, ZHANG Kai. Review of quality-related fault detection and diagnosis techniques for complex industrial processes. *Acta Automatica Sinica*, 2017, 43(3): 349 – 365.
(彭开香, 马亮, 张凯. 复杂工业过程质量相关的故障检测与诊断技术综述. 自动化学报, 2017, 43(3): 349 – 365.)
- [10] ZHANG K, HAO H, CHEN Z, et al. A comparison and evaluation of key performance indicator-based multivariate statistics process monitoring approaches. *Journal of Process Control*, 2015, 33(3): 112 – 126.
- [11] SCHÖLKOPF B, SMOLA A, MÜLLER K R. Kernel principal component analysis. *International Conference on Artificial Neural Networks*. Berlin Heidelberg: Springer, 1997: 583 – 588.
- [12] CHOI S W, LEE C, LEE J M, et al. Fault detection and identification of nonlinear processes based on kernel PCA. *Chemometrics & Intelligent Laboratory Systems*, 2005, 75(1): 55 – 67.
- [13] ROSIPAL R, TREJO L J. Kernel partial least squares regression in reproducing kernel hilbert space. *Journal of Machine Learning Research*, 2001, 2(2): 97 – 123.
- [14] JI H, HE X, LI G, et al. Determining the optimal kernel parameter in KPCA based on sample reconstruction. *Chinese Control Conference*. Chengdu, China: IEEE, 2016: 6408 – 6414.
- [15] XIAO Y, WANG H, XU W. Model selection of Gaussian kernel PCA for novelty detection. *Chemometrics & Intelligent Laboratory Systems*, 2014, 136(9): 164 – 172.
- [16] PENG Kaixiang, ZHOU Donghua, LI Na. Quality-related monitoring and control in hot strip mill process. *Control Engineering of China*, 2011, 18(4): 650 – 654.
(彭开香, 周东华, 李娜. 质量相关的带钢热连轧过程监控. 控制工程, 2011, 18(4): 650 – 654.)
- [17] LEE J M, YOO C K, CHOI S W, et al. Nonlinear process monitoring using kernel principal component analysis. *Chemical Engineering Science*, 2004, 59(1): 223 – 234.
- [18] MÜLLER K R, MIKA S, RÄTSCH G, et al. An introduction to kernel-based learning algorithms. *IEEE Transactions on Neural Networks*, 2001, 12(2): 181 – 201.
- [19] PENG K, ZHANG K, LI G. Online contribution rate based fault diagnosis for nonlinear industrial processes. *Acta Automatica Sinica*, 2014, 40(3): 423 – 430.
- [20] DONG D, MCAVOY T J. Nonlinear principal component analysis-based on principal curves and neural networks. *Computers & Chemical Engineering*, 1996, 20(1): 65 – 78.
- [21] LI Y, MAGUIRE L. Selecting critical patterns based on local geometrical and statistical information. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, 2011, 33(6): 1189 – 1201.
- [22] PENG Kaixiang, LI Gang, ZHANG Kai. Strip thickness monitoring in hot strip mill processes based on dynamic total projection to latent structures (T-PLS) algorithm. *Control Theory & Applications*, 2012, 29(11): 1446 – 1451.
(彭开香, 李钢, 张凯. 基于动态全潜结构投影的热连轧厚度监控. 控制理论与应用, 2012, 29(11): 1446 – 1451.)
- [23] SAMANTA B. Gear fault detection using artificial neural networks and support vector machines with genetic algorithms. *Mechanical Systems & Signal Processing*, 2004, 18(3): 625 – 644.
- [24] ZHAO Y, WANG S, XIAO F. Pattern recognition-based chillers fault detection method using support vector data description (SVDD). *Applied Energy*, 2013, 112(4): 1041 – 1048.

作者简介:

张凯 讲师, 主要研究方向为复杂工业过程监控、层次化数据建模、乘性故障诊断, E-mail: kaizhang@ustb.edu.cn;

齐恬婧 硕士研究生, 主要研究方向为非线性工业过程监控与故障诊断, E-mail: qitianjingqtj@163.com;

彭开香 教授, 主要研究方向为统计过程监控、动态过程建模、数据驱动的故障诊断与预测, E-mail: kaixiang@ustb.edu.cn;

储若慧 硕士研究生, 主要研究方向为工业过程监控与故障诊断, E-mail: aiki_ruohui@163.com.