

轧制

## 基于改进 HMM 的带钢热连轧精轧过程故障检测

张瑞成, 崔凯鑫, 梁卫征

(华北理工大学 电气工程学院, 河北 唐山 063210)

**摘要:** 针对传统 HMM 方法故障检测的准确率不高, 以及带钢热连轧过程数据的非线性和混合高斯性问题, 提出一种利用 WT 和 PCA 改进 HMM 的故障检测新方法。首先, 采用小波变换对轧制数据进行去噪处理, 并使用 PCA 将数据的维度降低、数据相关性减小, 可以有效减少模型训练的迭代次数, 并且能够提升故障检测的准确率; 然后, 利用期望最大化算法结合观测序列训练得到 WT-PCA-HMM 故障检测模型; 最后, 通过模型得出精轧工艺数据的对数似然值即可实现故障检测。结果表明: 与传统 HMM 方法相比, WT-PCA-HMM 的故障检测方法不仅能够降低 8.1% 的误报率, 而且减少 50% 的模型训练迭代次数, 为故障的检测提供了新方法。

**关键词:** 带钢; 热连轧; 故障检测; 小波变换; 主成分分析; 隐马尔科夫模型

**DOI:** 10.13330/j.issn.1000-3940.2023.03.017

**中图分类号:** TP273

**文献标志码:** A

**文章编号:** 1000-3940 (2023) 03-0126-06

## Fault detection of finish rolling process for hot strip rolling based on improved HMM

Zhang Ruicheng, Cui Kaixin, Liang Weizheng

(College of Electrical Engineering, North China University of Science and Technology, Tangshan 063210, China)

**Abstract:** A new method of fault detection was proposed to improve the HMM based on WT and PCA to solve the problems of low accuracy of the traditional HMM method and the nonlinearity and mixed Gaussianity of the hot strip rolling process data. Firstly, wavelet transform was used to denoise the rolling data, and PCA was used to reduce the dimensionality and correlation of the data, which can effectively reduce the number of iterations for model training and improve the accuracy of fault detection. Then, the WT-PCA-HMM fault detection model was obtained by using the expectation maximization algorithm combined with the training of observed sequence training. Finally, the logarithmic likelihood values of the finishing process data was derived from the model to achieve the fault detection. The results show that the WT-PCA-HMM fault detection method can not only reduce the false alarm rate by 8.1% compared with the traditional HMM method, but also reduce the number of model training iterations by 50%, which provides a new method for the fault detection.

**Key words:** strip steel; hot rolling; fault detection; wavelet transform; principal component analysis; hidden Markov model

随着工业的快速发展, 工业流程的复杂程度越来越高。带钢热连轧的精轧过程作为钢铁生产过程中必不可少的环节之一, 不仅程序复杂、动态性强, 还具有高速、高温、高精度等特性。这也导致精轧工艺成为故障率高且危险性较大的生产过程。因此, 精轧过程需要引入更加精准的故障检测方法来稳定生产的高效运行<sup>[1]</sup>。

振动信号一般被分为频域和时域两方面。傅里叶变换 (Fourier Transform, FT) 常用来提取频域信息, 主要应用在时域信号扰动较大从而需要处理频域信号的情况<sup>[2]</sup>。但 FT 对时域信号或突变和非平稳信号的处理效果不佳。小波变换 (Wavelet Transform, WT) 能够兼顾时域和频域的信息, 且对于非平稳信号来说, 也具有很强的处理能力<sup>[3]</sup>。

目前, 生产过程普遍比较复杂, 精确的机理模型很难建立, 因此, 越来越多的基于数据的方法开始涌现出来<sup>[4]</sup>。在带钢热连轧领域中, 变量的复杂性主要包括非高斯性、动态性以及时变性<sup>[5]</sup>。目前, 基于数据的方法主要以主成分分析 (Principal Component Analysis, PCA)、典型变量分析 (Canon-

收稿日期: 2022-05-22; 修订日期: 2022-08-27

基金项目: 河北省自然科学基金资助项目 (F2018209201); 唐山市科技局科技计划项目 (22130213G); 河北省省属高校基本科研业务费资助项目 (JQN2021021)

作者简介: 张瑞成 (1975-), 男, 博士, 教授

E-mail: rchzhang@126.com

ical Variate Analysis, CVA)、独立成分分析 (Independent Component Analysis, ICA) 为主。如果单独使用 PCA 或核 PCA, 检测故障的效果比较好, 但要求数据必须符合高斯分布<sup>[6-8]</sup>。CVA 和 ICA 方法能够在工业过程数据中提取独立源, 但是应用在动态过程中效果并不理想<sup>[9-10]</sup>。

隐马尔科夫模型 (Hidden Markov Model, HMM) 是越来越常见的以数据和概率为基础的检测方法。由于其具有严密的数学理论、强大的建模能力, 因此, 不仅能对未知状态进行准确地识别, 还比较善于处理信息丰富、非平稳性强且信息难以重复出现的信号<sup>[11]</sup>。文献 [12] 针对 HMM 中的 BW 算法容易产生局部极值从而导致模型诊断结果精度不够的问题, 提出通过惯性权重因子来改进粒子群算法的方法, 达到了提升诊断效率和精度的目的。文献 [13] 通过小波分解和 HMM 结合达到定位轴承故障位置和诊断故障严重程度的目的, 采用小波分解对数据进行处理得到检测指标向量, 使用 HMM 对不同状态建模, 最后对实时数据使用 HMM 进行故障程度的识别。文献 [14] 针对汽车排气系统的数据特点, 将 HMM 处理后的数据输出作为贝叶斯网络的经验, 用于故障检测和故障预测, 达到了提高故障检测速度的目的。在铲运机领域中, 针对故障信息难以准确表达而影响铲运机故障预测和识别的情况, 文献 [15] 使用最小二乘改进的支持向量机对数据进行优化, 使用 HMM 对铲运机被优化的数据进行识别, 提升了铲运机电控系统故障预测的准确率。文献 [16] 针对经验模态分解 (Empirical Mode Decomposition, EMD) 容

易出现模态混叠的问题, 提出通过集合经验模态分解 (Ensemble Empirical Mode Decomposition, EEMD) 来得到各阶固有模态分量, 然后通过 HMM 进行故障识别和诊断, 这样能够更加精确地对故障进行识别和诊断。HMM 在很多领域中均有应用, 但在带钢热连轧领域的应用较少。尽管 HMM 适合处理带钢热连轧领域的的数据, 但此方法仍存在故障识别准确率不高、模型训练复杂的问题。因此, 引入了 WT 和 PCA 的方法对 HMM 进行了改进。

首先, 使用 WT 对数据进行去噪, 使用 PCA 方法降低数据的相关性、减少数据的维度, 以减少模型训练迭代次数, 并提升故障检测的准确率。然后, 训练 HMM 并保存精轧工艺正常数据的对数似然 (Log-Likelihood,  $LL$ ) 值。最后, 利用精轧工艺 WT-PCA-HMM 对实时数据进行故障检测。

## 1 带钢热连轧过程介绍

带钢热连轧系统是一个十分复杂的动态工艺流程, 其工艺流程如图 1 所示。在粗轧阶段, 钢板的厚度会大幅度减小, 因此, 钢板长度会成比例地增加。钢板通过辊道运输后, 为了避免工作辊损坏, 需要飞剪对钢板的头部和尾部进行切割。然后作为工业带钢热连轧过程的核心步骤即精轧过程, 将对钢板进行更加精确地轧制, 使钢板的厚度进一步降低, 直至达到预期厚度要求, 此过程即为故障检测的研究过程。最后, 钢板经过层流冷却设备后卷成需要的产品。




图 1 带钢热连轧工艺流程图

Fig. 1 Process flow chart of hot strip rolling

带钢热连轧过程主要由加热、粗轧、飞剪、精轧、层流冷却、卷取等生产工序构成。精轧机架由 7 组工作辊、支撑辊和液压压下装置构成<sup>[17]</sup>。用于检测轧制力的装置设置在下支撑辊底部。辊缝为了达到规定的出口厚度而设定参数, 并且还有自动厚度控制系统 (Automatic Gauge Control, AGC) 及其他各种控制器来保证出口厚度的精准控制。连续可变凸度 (Continuously Variable Crown, CVC)<sup>[18]</sup>、工

作共移动轧机<sup>[19]</sup> (Kawasaki-work Roll Shifting,  $k$ -WRS) 和非对称自补偿轧制 (Asymmetry Selfcompensating Rolling, ASR)<sup>[20]</sup> 工作辊窜辊和工作辊液压弯辊力等热轧板形控制技术对于带钢板形有很大的改善作用

本文研究对象是带钢热连轧过程中的精轧工艺, 精轧工艺的数据具有短时产生数据量大、数据种类复杂、受环境影响较大等特点。与此同时, 精轧工

艺数据一般不止符合一种高斯模型,基本为多种高斯模型混合的情况。

以典型的 1700 mm 带钢热连轧生产线为背景,通过 HMM 及其他辅助算法对精轧机组振动数据进行检测。主要参数包括每个机架的辊缝和轧制力以及后 6 个机架的弯辊力。

表 1 过程及质量变量分配

Table 1 Allocation of process and quality variables

变量序号	类型	描述	单位
1~7	过程变量	第 $c$ 个机架的平均辊缝 ( $c=1, 2, 3, 4, 5, 6, 7$ )	mm
8~14	过程变量	第 $c$ 个机架的轧制力 ( $c=1, 2, 3, 4, 5, 6, 7$ )	MN
15~20	过程变量	第 $c$ 个机架的弯辊力 ( $c=1, 2, 3, 4, 5, 6, 7$ )	MN
21	质量变量	精轧末机架的出口厚度	mm

## 2 基于 WT-PCA-HMM 的故障检测模型

### 2.1 小波变换

小波变换由于其自身去相关性和选基灵活的特征而被应用到很多领域。

观测信号的连续小波变换为:

$$W(a, b) = \int_{-\infty}^{\infty} f(t) \psi_{a,b}^*(t) dt = \langle f(t), \psi_{a,b}(t) \rangle \quad (1)$$

其中:

$$\psi_{a,b}(t) = |a|^{-1/2} \psi_a\left(\frac{t-b}{a}\right) \quad (2)$$

式中:  $a$  为尺度因子;  $b$  为平移因子;  $W(a, b)$  为  $a$  与  $b$  的函数, 代表经过小波变换后的信号;  $f(t)$  为任意给定的时域信号;  $t$  为时间;  $\psi_{a,b}(t)$  为小波基函数;  $*$  表示复数共轭。

小波去噪过程包括以下 3 个步骤。

(1) 确定所需小波基和分解层数, 对信号进行分解能够得到  $W(a, b)$ 。

(2) 对  $W(a, b)$  设置阈值  $\eta$ :

$$\eta = \varepsilon \sqrt{2 \ln g} \quad (3)$$

式中:  $\varepsilon$  为噪声方差;  $g$  为小波分解层数。

通过式 (3) 阈值处理可以去除观测数据中的噪声。

(3) 对  $W(a, b)$  重构可得到去噪后的信号。

### 2.2 主成分分析

主成分分析不仅能够降低数据的相关性, 还可

以达到降低数据维度、减小计算量的目的。

使用 PCA 对数据进行降维的具体步骤如下。

(1) 将去噪后的精轧工艺数据构造成  $m$  行  $n$  列的矩阵  $D$  (其中,  $m$  为样本总个数,  $n$  为测量变量个数)。

(2) 计算每个变量读数的均值矩阵  $\mu$ :

$$\mu = \frac{1}{m} \sum_{i=1}^m D_i \quad (4)$$

式中:  $D_i$  为第  $i$  个样本对应的矩阵,  $i=1, 2, 3, \dots, m$ 。

(3) 根据均值矩阵  $\mu$  将数据居中, 得到居中处理后的数据矩阵  $Z$ :

$$Z = D - \mu^T \quad (5)$$

(4) 计算矩阵  $D$  的特征值  $\lambda_1, \lambda_2, \dots, \lambda_m$ , 以及所对应的特征向量  $e_1, e_2, \dots, e_m$ 。

(5) 确定第  $i$  个样本的主成分贡献率  $\theta_i$ , 一般要求主成分贡献超过 85%。

$$\theta_i = \frac{\lambda_i}{\sum_{i=1}^m \lambda_i}, i=1, 2, \dots, m \quad (6)$$

(6) 根据  $\theta_i$  由大到小取  $k$  个特征值所对应的特征向量组成矩阵  $E=[e_1, e_2, \dots, e_k]$ , 降维后的数据矩阵  $O$  为:

$$O = E^T Z \quad (7)$$

经过 PCA 处理后的去噪精轧工艺数据不仅包含大量的原始信息, 还能够大大减少计算量, 减小模型训练所需的迭代次数, 因此, 能够节省模型训练所需时间, 故障检测的准确度有所提升。

### 2.3 WT-PCA-HMM 故障检测模型

将经过 PCA 处理后的去噪精轧工艺数据作为观测序列对 HMM 进行训练, 构建 WT-PCA-HMM 故障检测框架, 以达到能够更准确地检测带钢热连轧过程精轧工艺故障的目的, 具体流程图如图 2 所示。HMM 部分由两方面构成, 即隐马尔可夫链和观察序列。隐马尔可夫链由一些无法直接观测到的隐状态构成, 可分为故障和正常两种隐状态。观测值是每种隐状态的可观测数据, 即经过 PCA 处理后的精轧工艺中故障和正常情况下对应的数据。

WT-PCA-HMM 可由以下参数表示。

(1) 隐状态数为  $N$ 。在模型中定义  $N$  个隐状态, 则  $t$  时刻的隐状态  $q_t$  表示为:

$$q_t \in [S_1, \dots, S_N] \quad (8)$$

式中:  $S_1, \dots, S_N$  分别对应第 1~ $N$  个隐状态。

(2)  $t$  时刻的观测数据记为:

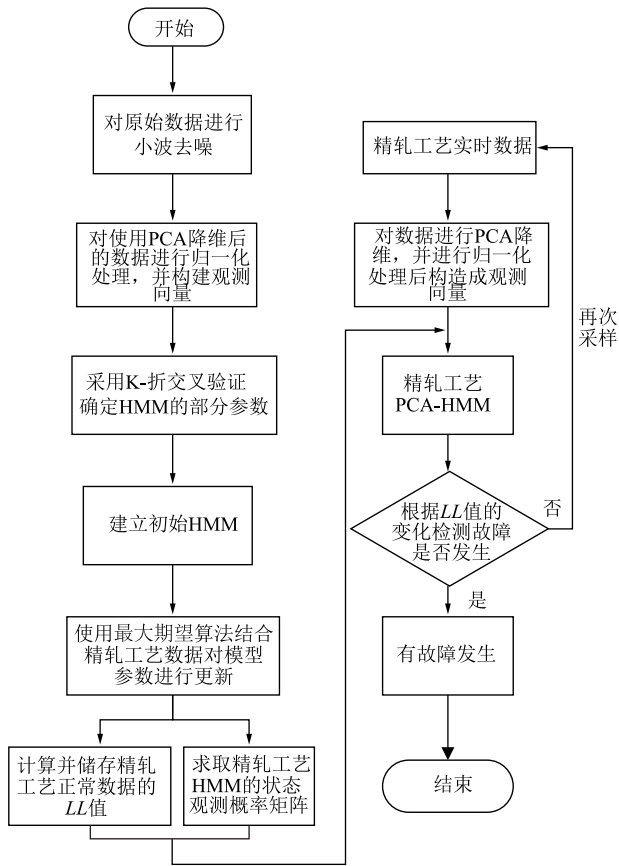


图2 PCA-HMM 故障检测流程图

Fig. 2 Flow chart of PCA-HMM fault detection

$$\mathbf{O}_t = (V_1, V_2, \dots, V_M) \quad (9)$$

式中： $V_1, \dots, V_M$  分别为  $t$  时刻的第 1~ $M$  个维度的观测数据； $\mathbf{O}_t$  为  $t$  时刻的观测数据矩阵。

(3) 将隐状态转移矩阵  $\mathbf{A}$  在  $t$  时刻的隐状态记为  $S_u$  ( $t$  时刻有  $u$  种可能出现的隐状态) 则, ( $t+1$ ) 时刻的隐状态为  $S_v$  的概率记为:

$$\mathbf{A} = \{a_{uv}\} \quad (10)$$

式中： $a_{uv}$  为  $t$  时刻隐状态为  $S_u$  的情况下, ( $t+1$ ) 时刻的隐状态为  $S_v$  的概率； $u \neq v, u \geq 1, v \geq 1$ 。

(4) 隐状态观测概率矩阵  $\mathbf{B}$ , 即正常和故障两种隐状态分别对应观测值的概率记为:

$$\mathbf{B} = (b_{vw}) \quad (11)$$

式中： $b_{vw}$  为隐状态为  $S_v$  时输出数据为  $V_w$  的概率； $V_w$  为观测数据矩阵  $\mathbf{O}_t$  中的第  $w$  个维度的观测数据。

(5) 初始隐状态概率矩阵, 将初始隐状态为故障或正常的概率记为  $\eta$ , 则第 1 个隐状态的概率  $P$  记为:

$$\eta = P(q_1 = S_r), 1 \leq r \leq N \quad (12)$$

式中： $q_1$  为初始隐状态。

精轧工艺 PCA-HMM 由以上 5 个参数构成, 其

中  $N$  和  $M$  不需要训练, 因此, 将精轧工艺 PCA-HMM 记为  $\lambda$ , 其表达式为:

$$\lambda = (\mathbf{A}, \mathbf{B}, \eta) \quad (13)$$

精轧工艺数据的密度函数为:

$$f(\mathbf{O}, \mu, \sigma) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(v-\mu)^2}{2\sigma^2}} \quad (14)$$

式中： $V$  为测量数据的值； $\mu$  为测量数据的平均值； $\sigma$  为测量数据的方差。

则  $\mu$  和  $\sigma$  的似然函数为:

$$L(\mu, \sigma) = \prod_{j=1}^n \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(V_j-\mu)^2}{2\sigma^2}} = \left(\frac{1}{\sqrt{2\pi}}\right)^n \left(\frac{1}{\sigma}\right)^n e^{-\frac{(V_1-\mu)^2 + \dots + (V_n-\mu)^2}{2\sigma^2}} \quad (15)$$

式中： $V_1 \sim V_n$  为观测数据具体数值； $j=1, \dots, n$ ,  $n$  为观测数据总数。

对数似然函数为:

$$\ln[L(\mu, \sigma)] = n \ln \frac{1}{\sqrt{2\pi}} - \frac{n}{2} \ln \sigma^2 - \frac{(V_1 - \mu)^2 + \dots + (V_n - \mu)^2}{2\sigma^2} \quad (16)$$

### 3 WT-PCA-HMM 的训练

得到精轧工艺 WT-PCA-HMM 模型的过程需要解决学习问题。即已知精轧机组的观测序列  $\mathbf{O}$  和初始设置的模型参数, 然后对模型参数进行更新, 从而得到符合给定观测序列的 WT-PCA-HMM。

(1) 将精轧工艺中的采样数据进行小波去噪处理。

(2) 将去噪后的数据通过 PCA 方法进行降维处理, 并进行归一化得到构建精轧工艺 WT-PCA-HMM 的观测序列。

(3) 预先设定参数: 分别确定精轧工艺中的隐藏状态数  $N$ 、样本数量  $m$ , 通过 K-折交叉验证确定训练数据的高斯混合数  $M$ 。

(4) 建立隐马尔科夫模型:  $\lambda = (\eta, \mathbf{A}, \mathbf{B})$ , 预设  $\eta$  和  $\mathbf{A}$ , 对观测序列的均值、标准差、高斯混合矩阵进行估计。

(5) 根据观测序列 (data) 使用期望极大算法 (Expectation Maximization, EM) 对均值、标准差、高斯混合矩阵、 $\eta$  和  $\mathbf{A}$  的初始估计值进行更新。

(6) 根据观测序列、均值、标准差、高斯混合矩阵、 $\eta$  和  $\mathbf{A}$  计算并保存观测序列的对数似然值。



(7) 根据观测序列、均值、标准差和高斯混合矩阵对  $B$  进行计算, 得到精轧工艺 WT-PCA-HMM。

在训练 WT-PCA-HMM 时, 使用 EM 对模型进行迭代。根据去噪并进行 PCA 处理的精轧工艺的正常数据得到模型的新参数, 使模型能够准确检测数据中的故障。当  $LL$  值趋近于平稳时, 代表模型的参数能够准确识别振动数据是否正常。

通过 WT 和 PCA 对 HMM 进行改进后, 很大程度上减小了计算量, 因此, 对模型训练速度的提升有着至关重要的作用。具体训练过程对比如图 3 所示。




图 3 精轧工艺故障检测模型训练速度对比图

Fig. 3 Comparison diagram of training speed for finish rolling process fault detection model

图 3 中, 横轴为不同模型达到能够分辨是否为故障数据所需的迭代次数, 纵轴为模型处理精轧机组数据的对数似然值, 当对数似然值稳定后, 即训练完毕。WT-PCA-HMM 迭代 9 次后, 数值趋于稳定, 表示训练结束。而 PCA-HMM 和 HMM 分别需要迭代 14 和 18 次数据才能够得到训练好的模型, 因此, WT-PCA-HMM 的训练时间仅为 HMM 训练时间的 50%。

#### 4 精轧工艺过程的故障检测

仿真中第 5 机架弯辊力的数值发生阶跃突变产生故障, 即变量 18 的值会发生阶跃变化。在第 1000 ms 处突然发生故障, 并在 1000 ms 后结束, 期间的采样间隔为 1000 ms。

模型训练完成后, 对 WT-PCA-HMM、PCA-HMM 和传统 HMM 方法进行了故障检测结果对比。图 4 为使用传统 HMM 方法对精轧工艺故障进行故障检测的结果图, 图 5 为使用 WT-PCA-HMM 对精轧工艺故障进行故障检测的结果图。

图 5 中, 曲线部分为检测数据中每组采样数据




图 4 精轧工艺 HMM 故障检测结果

Fig. 4 HMM fault detection results in finish rolling process




图 5 WT-PCA-HMM 故障检测结果

Fig. 5 WT-PCA-HMM fault detection results

对应的对数似然值, 横线为对数似然值的平均值, 两条竖线之间为模型检测到故障的数据组。图 4 未能精准地检测到故障, 从 2000~3300 ms 应均为正常情况, 但是传统 HMM 出现了误检的情况。图 5 为 PCA-HMM 故障检测结果图, 从图 5 中可以看出 0~1000 ms 和 2000~3300 ms 之间的正常数据给出了较高的似然值, 表明数据对于精轧工艺 PCA-HMM 的符合程度较高, 被识别为正常数据。而 1000~2000 ms 之间的故障数据给出了较低的对数似然值, 表明 1000~2000 ms 之间的数据和正常数据具有较大的差异, 被检测为故障。结果表明, 使用 WT-PCA-HMM 的方法对带钢热轧过程的精轧工艺进行故障检测的过程中, 未出现误检的情况。

#### 5 结论

(1) 使用小波去噪通过 PCA 降低数据相关性, 并减少数据的维度, 能够有效减小模型的计算量, 结果表明, WT-PCA-HMM 的训练迭代次数较传统

HMM 训练迭代次数减少了 50%。

(2) WT-PCA-HMM 的故障检测方法由于减少了噪声对数据的影响并降低了数据的相关性, 因此, 模型训练的精度更高, 相比于传统的 HMM, 能够更精确地检测到故障发生的数据点, 而不会出现误报的现象。

#### 参考文献:

- [1] 张瑞成, 裴然. 基于核独立元分析的非线性工业过程故障诊断 [J]. 科学技术与工程, 2020, 20 (17): 6944-6949.  
Zhang R C, Pei R. Fault diagnosis of nonlinear industrial process based on kernel independent component analysis [J]. Science Technology and Engineering, 2020, 20 (17): 6944-6949.
- [2] 朱亚军, 胡建钦, 李武, 等. 基于频域窗函数的短时傅里叶变换及其在机械冲击特征提取中的应用 [J]. 机床与液压, 2021, 49 (18): 177-182.  
Zhu Y J, Hu J Q, Li W, et al. Short-time fourier transform based on frequency-domain window function and its application in mechanical impulse feature extraction [J]. Machine Tool & Hydraulics, 2021, 49 (18): 177-182.
- [3] 彭成, 王松松, 贺婧, 等. 基于离散小波变换和随机森林的轴承故障诊断研究 [J]. 计算机应用研究, 2021, 38 (1): 101-105.  
Peng C, Wang S S, He J, et al. Research on bearing fault diagnosis based on discrete wavelet transform and random forest [J]. Application Research of Computers, 2021, 38 (1): 101-105.
- [4] 彭开香, 张传放, 马亮, 等. 面向系统层级的复杂工业过程全息故障诊断 [J]. 化工学报, 2018, 70 (2): 590-598.  
Peng K X, Zhang C F, Ma L, et al. System-levels-based holographic fault diagnosis for complex industrial processes [J]. Journal of Chemical Industry and Engineering, 2018, 70 (2): 590-598.
- [5] 朱金林. 数据驱动的工业过程鲁棒监测 [D]. 浙江: 浙江大学, 2016.  
Zhu J L. Robust Monitoring of Industrial Process with Data-driven Methods [D]. Zhejiang: Zhejiang University, 2016.
- [6] 彭开香, 周东华, 李娜. 质量相关的带钢热连轧过程监控 [J]. 控制工程, 2011, 18 (4): 650-654.  
Peng K X, Zhou D H, Li N. Quality-related monitoring and control in hot strip mill process [J]. Control Engineering of China, 2011, 18 (4): 650-654.
- [7] Zhang Y Y, Jia Y X, Guo C M, et al. Intelligent fault diagnosis of engine based on PCA-SOM [J]. Journal of Physics: Conference Series, 2020, 1453 (1): 012022-012022.
- [8] 马金英, 孟良, 许同乐, 等. 基于 FastICA 的遗传径向基神经网络轴承故障诊断研究 [J]. 机床与液压, 2021, 49 (18): 188-192.  
Ma J Y, Meng L, Xu T L, et al. Research on bearing fault diagnosis of genetic radial basis function neural network based on FastICA [J]. Machine Tool & Hydraulics, 2021, 49 (18): 188-192.
- [9] 张宇婷, 程方晓, 魏巍. 小波变换结合 CVA 的变压器故障诊断 [J]. 长春工业大学学报, 2020, 41 (5): 447-453.  
Zhang Y T, Cheng F X, Wei W. Transformer fault diagnosis based on DGA [J]. Journal of Changchun University of Technology, 2020, 41 (5): 447-453.
- [10] Zhou P, Zhang R Y, Xie J, et al. Data-driven monitoring and diagnosing of abnormal furnace conditions in blast furnace ironmaking: An integrated PCA-ICA method [J]. IEEE Transactions on Industrial Electronics, 2020, 68 (1): 622-631.
- [11] 侯一民, 周慧琼, 王政一. 深度学习在语音识别中的研究进展综述 [J]. 计算机应用研究, 2017, 34 (8): 2241-2246.  
Hou Y M, Zhou H Q, Wang Z Y. Overview of speech recognition based on deep learning [J]. Application Research of Computers, 2017, 34 (8): 2241-2246.
- [12] 郭森, 王大为, 张绍伟, 等. 自适应粒子群优化的 HMM 故障诊断方法及应用 [J]. 振动与冲击, 2021, 40 (20): 264-270.  
Guo S, Wang D W, Zhang S W, et al. A fault diagnosis method with application of HMM based on adaptive particle swarm optimization [J]. Journal of Vibration and Shock, 2021, 40 (20): 264-270.
- [13] 孙群丽, 刘长良, 甄成刚. 隐马尔科夫模型在滚动轴承故障诊断中的应用 [J]. 热能动力工程, 2018, 33 (10): 95-100.  
Sun Q L, Liu C L, Zhen C G. Application of hidden markov model in fault diagnosis of rolling bearing [J]. Journal of Engineering for Thermal Energy and Power, 2018, 33 (10): 95-100.
- [14] Soleimani M, Campean F, Neagu D. Integration of hidden markov modelling and bayesian network for fault detection and prediction of complex engineered systems [J]. Reliability Engineering System Safety, 2021, 215 (4): 107808.
- [15] 邹双宇, 靳添絮, 刘立, 等. 基于优化的 LSSVM-HMM 混合动力铲运机故障预测 [J]. 煤炭学报, 2019, 44 (S1): 338-344.  
Xun S Y, Jin T X, Liu L, et al. Fault prediction of hybrid scraper based on optimized LSSVM-HMM [J]. Journal of China Coal Society, 2019, 44 (S1): 338-344.
- [16] 谢蓉仙, 任芳, 杨兆建. EEMD 与 HMM 在齿轮故障诊断方法中的研究 [J]. 机械设计与制造, 2021, (1): 28-31.  
Xie R X, Ren F, Yang Z J. Research on EEMD and HMM in gear fault diagnosis method [J]. Machinery Design & Manufacture, 2021, (1): 28-31.
- [17] 马亮. 复杂工业过程质量相关故障的根源诊断与传播路径辨识 [D]. 北京: 北京科技大学, 2019.  
Ma L. Root Cause Diagnosis and Propagation Path Identification of Quality-related Faults for Complex Industrial Processes [D]. Beijing: University of Science and Technology Beijing, 2019.
- [18] Berger S, Hoen K, Hof H, et al. Evolution of CVC Plus © technology in hot rolling mills [J]. Metallurgical Research & Technology, 2008, 105 (1): 44-49.
- [19] Li Y L, Cao J G, Qiu L, et al. Research on ASR work roll contour suitable for all width electrical steel strip during hot rolling process [J]. International Journal of Advanced Manufacturing Technology, 2018, 97 (9-12): 3453-3458.
- [20] Cao J G, Liu S J, Jie Z, et al. ASR work roll shifting strategy for schedule-free rolling in hot wide strip mills [J]. Journal of Materials Processing Technology, 2011, 211 (11): 1768-1775.