DOI: 10.3901/JME.2020.08.250

基于温度时序特征层次聚类的连铸 黏结漏钢预报方法开发*

段海洋^{1,2} 王旭东^{1,2} 姚 曼^{1,2}

(1. 大连理工大学材料科学与工程学院 大连 116024;

2. 大连理工大学辽宁省凝固控制与数字化制备技术重点实验室 大连 116024)

摘要: 黏结漏钢的准确识别和预报对于连铸全流程的控制至关重要。黏结漏钢是连铸过程中最具危害的重大事故,如果不能及时、准确地对黏结漏钢进行提前预测和处置,由此带来的漏报、误报不仅严重损坏铸机设备,还将极大影响铸坯质量和生产顺行,带来巨大经济损失。为了捕捉和识别黏结漏钢时结晶器铜板的温度时序特征,将层次聚类(Hierarchical clustering)与动态时间弯曲(Dynamic time warping, DTW)计算方法相结合,构建并开发了一种基于机器学习的新型黏结漏钢预报方法。与现场服役的漏钢预报系统进行测试和对比,结果显示,建立的方法在保证真黏结 100%报出率的同时,将误报次数降低了近 60%,大幅提高了黏结漏钢预报准确率,避免了由错误报警引起的铸机降速或停机,对于促进连铸过程顺行、稳定和改善连铸坯质量具有积极意义。基于聚类的黏结漏钢预报方法展示出良好的应用潜力,为连铸过程异常监控提供了新思路。

关键词: 时序特征; 层次聚类; 动态时间弯曲; 漏钢预报

中图分类号: TG245

Development of Sticking Breakout Prediction Method Based on Hierarchical Clustering of Temperature Timing Characteristics in Continuous Casting

DUAN Haiyang^{1,2} WANG Xudong^{1,2} YAO Man^{1,2}

(1. School of Materials Science and Engineering, Dalian University of Technology, Dalian 116024;

2. Key Laboratory of Solidification Control and Digital Preparation Technology (Liaoning Province),
Dalian University of Technology, Dalian 116024)

Abstract: Accurate identification and prediction for the sticking breakout is of great significance for the control of continuous casting process. Sticking breakout is the most dangerous accident in continuous casting. If the breakout cannot be predicted and disposed in time and accurately, the resulting missing and false alarms will seriously damage the caster equipment and affect the quality of the slabs, which causes huge economic losses. The hierarchical clustering and dynamic time warping (DTW) are combined to capture and identify the temperature timing characteristics during sticking breakout, and then, a new sticking breakout prediction method based on machine learning is developed. Compared with the in-service breakout prediction system, the proposed method can reduce the number of false alarms by about 60% with a 100% correct true alarm rate. The method can greatly improve the prediction accuracy and avoid the casting speed reduction or shutdown caused by false alarms, which is of positive significance for smooth stability and slab quality. The sticking breakout prediction method based on clustering shows excellent application potential and provides a new approach for abnormal monitoring in continuous casting.

Key words: timing characteristics; hierarchical clustering; dynamic time warping; breakout prediction

* 国家自然科学基金(51474047)和中央高校基本科研业务费资助项目。
20190403 收到初稿, 20191016 收到修改稿

0 前言

黏结漏钢是连铸生产过程中最严重的灾难性事故, 不仅危及现场人员的人身安全、损坏连铸设备, 同时将导致生产被迫中断, 给连铸坯质量和生产顺利进行带来严重影响^[1]。黏结漏钢是指结晶器内凝固坯壳的薄弱处发生破裂而导致钢液渗出。导致黏结漏钢的主要原因是结晶器弯月面附近^[2], 因保护渣润滑不良促使坯壳与结晶器铜板发生黏结^[3-4], 造成坯壳破裂而出现黏结漏钢。

现有基于温度测量的漏钢预报方法主要分为逻辑判断方法^[5-6]和人工智能方法^[7-8], 虽能保证一定的准确率, 但在高效连铸技术发展的过程中, 高拉速引发的漏报和误报(生产正常而漏钢预报系统发出报警)时有发生^[9]。虽然误报对铸机设备的破坏性低于漏报, 但漏钢预报系统发出误报信号后, 采取的急降拉速措施会降低铸坯的表面和内部质量, 甚至导致铸坯判废。因此, 如何在确保避免漏报的前提下有效减少误报, 是目前结晶器漏钢预报方法开发面临的关键。

在发生黏结漏钢时, 结晶器铜板热电偶温度呈现出明显的单偶时间序列特征和组偶空间联动特征。单偶的温度序列特征指单排温度序列随时间先上升后下降, 且其变化幅度、变化速率在趋势上满足一定的连续变化条件。组偶的空间联动特征指上下排单偶温度序列特征的交替出现, 且下排相较于上排有时间上的滞后性。单偶的温度序列特征和组偶的空间联动特征共同构成了黏结漏钢时热电偶的温度时序特征, 温度时序特征是辨识和区分正常工况和漏钢模式温度的重要依据。

逻辑判断方法和神经网络方法一般是从原始温度中提取出多个独立的特征, 再对其进行联立判断或加权, 往往忽视了单偶的完整时序特征和组偶的空间联动特征。鉴于黏结漏钢时单偶的时序特征和组偶空间联动特征十分相似, 与正常工况下热电偶温度的平稳变化存在显著差异, 本文将层次聚类与动态时间弯曲(Dynamic time warping, DTW)算法有机结合, 提取单偶和组偶温度变化的共性特征, 以区分和识别黏结漏钢, 开发基于机器学习聚类的漏钢预报方法, 为连铸过程异常预报提供参考和新的思路。

1 黏结漏钢的温度时间序列特征

国内外现有的漏钢预报方法, 主要通过监测安装在结晶器铜板上的热电偶的温度变化对漏钢进行预测。图 1 所示为某钢厂在线服役的结晶器及其热

电偶分布示意图。结晶器铜板长度为 900 mm, 有效高度为 800 mm, 由四块铜板组合而成。内、外弧宽面铜板各安装了 3 排 19 列热电偶, 左、右侧窄面铜板各安装了 3 排 1 列热电偶, 四张铜板共计安装 120 支热电偶。其中, 第一排热电偶距结晶器上口的距离为 210 mm, 第一、二排热电偶之间的间距为 115 mm, 第二、三排热电偶之间的间距为 120 mm, 相邻两列热电偶之间的间距为 150 mm。

图 1 结晶器铜板热电偶分布

图 2 所示为铸坯在结晶器中发生黏结漏钢时热电偶温度变化示意图。正常工况下, 结晶器铜板热电偶温度随时间变化平稳, 不会出现较大波动。沿浇铸方向, 铸坯坯壳厚度及其向结晶器铜板传热热阻逐渐增加, 下排热电偶的温度逐次下降, 如图 2 中第 I 阶段所示。在弯月面附近, 由液位波动剧烈、润滑恶化等因素导致薄弱的坯壳被撕裂, 钢液从裂口渗出并与铜板直接接触, 造成黏结。随着结晶器振动和铸坯下行, 黏结处逐渐下移并左右扩展, 当其靠近并经过第一排热电偶时, 该处测点温度会先上升后下降, 且第二排热电偶温度随之上升, 如图 2 中第 II、III 阶段所示。随着黏结处经过第二排热电偶, 其温度亦会逐渐下降, 如第 IV 阶段所示。

图 2 黏结漏钢时热电偶温度变化趋势

从图 2 中亦可以看出, 下排热电偶温度的上升和下降较之上排有明显的滞后, 称之为“温度时滞”。此外, 上排热电偶在下降的同时伴随着下排热电偶温度的上升, 且会出现温度高于上排热电偶的情况, 称之为“温度倒置”。热电偶温度的“时滞”和空间“倒置”现象是黏结漏钢典型的特征, 也是当前预

报黏结漏钢的主要依据^[10]。

实践中为尽力避免漏报,在设计预报算法或设置报警阈值时往往留有调整余地。然而,由于不同工况条件下温度的幅值、变化率等单偶时间序列特征差异较大,参数或阈值的设置不当易导致误报甚至漏报。此外,基于逻辑判断或神经网络的预报方法更加关注电偶的温度突变、上升/下降幅值和速率等,对上下排组偶温度的联动变化关注甚少,准确捕捉黏结漏钢的“时滞”和“倒置”特征较为困难。上述原因均是造成误报几率增大的重要因素,频繁误报成为目前漏钢预报系统面临的普遍问题。

2 温度时间序列特征构造

基于上述分析,已有漏钢预报方法通过给定阈值或将其限定在一定范围,对漏钢进行捕捉和预警。这种方法对数据处理和特征模式提取的依赖较强,不可避免地受到人为因素的干扰。同时,受拉速、钢种和浇铸工艺的影响也较大,需要不断调整模型和参数,样本的选取和制作繁琐,给神经网络的预报精度带来负面影响。

为克服以上问题,同时为满足在线检测和预报的实时性要求,本文重点考虑对黏结漏钢更为敏感、离弯月面最近的第一和第二排热电偶温度,尽量简化对温度数据的预处理过程,以回避人为主观因素对原始数据带来的干扰,尽力保留全体温度数据的初始特征。以未经人为干预和处理的原始温度数据为基础,本文尝试构造包括单偶时间序列特征和组偶空间联动特征在内的热电偶温度时序特征,对温度时间序列做以下处理。

2.1 第一排温度变化率

第一排热电偶的温度变化趋势,尤其是温度变化率趋势,对于单偶时间序列特征的识别至关重要。原因在于,温度变化率可以提取温度上升和下降的趋势和幅度。同时,由于不同拉速及工艺条件下的电偶温度相差较大,温度变化率能将相差较大的温度数据缩放到同一变化区间,便于相似性或距离的度量。温度变化率的计算公式如下

$$v_i = \frac{T_{i+5} - T_i}{5} \quad i = 1, 2, \dots, 20 \quad (1)$$

式中, T_i 表示温度时间序列第 i 时刻的温度; v_i 为第一排温度对应的温度变化率。

2.2 第一、二排温度变化率差值

空间组偶特征是判断组偶空间联动变化的重要依据,而上下排温度升降交替的出现是反映空间联动变化最为直观的现象。为提取此特征,可将第一、

二排的单偶时序特征,即第 2.1 节所述的温度变化率作差,由此捕获其温度在升降交替过程中出现的温度“时滞”及“倒置”。温度变化率差值计算公式如下

$$v_minus_i = v_{1i} - v_{2i} \quad i = 1, 2, \dots, 20 \quad (2)$$

式中, v_{1i} 、 v_{2i} 分别表示第一、二排温度对应的温度变化率; v_minus_i 表示其差值。

2.3 第二排温度归一化

当单偶温度时间序列与空间组偶特征同时出现后,可基本判定为黏结漏钢。组偶空间联动变化的出现标志着下排热电偶温度的上升,但由于不同拉速及工艺条件,下排单偶温度上升的幅度大小不一,若幅度过小,则其与出现温度时序特征的其他样本的相似性较小,在漏钢预报时易造成漏报。为此,将第二排温度进行归一化处理,以消除因不同拉速及工艺条件引起的下排温度上升幅度不一致的情况。温度归一化处理公式如下

$$nor_i = \frac{T_i - T_{\min}}{T_{\max} - T_{\min}} \quad i = 1, 2, \dots, 25 \quad (3)$$

式中, $T_{\min}$ 、 $T_{\max}$ 分别表示温度时间序列的最小值、最大值。

以上处理并未提取温度变化的单独特征,而是从时间、空间角度综合考虑了温度、温度速率、时滞及倒置,对原始温度进行整体处理,以覆盖和包含黏结漏钢过程中同列热电偶典型的温度变化。

图 3a~3c、3d~3e 分别为误报和黏结漏钢温度的时间序列特征。从图 3 中可以看出,不同模式的温度时间序列在构造后所得曲线呈现出极大差异。

图 3 误报与黏结漏钢情况下温度时序特征

3 基于动态时间弯曲的距离度量方法

在不同的拉速和浇铸工艺条件下,温度变化率、幅值、温度极值以及时滞间隔均有所不同,且不同拉速下黏结传播速度不同,温度和温度速率曲线沿

时间轴发生拉伸、压缩或平移, 曲线峰值不对应, 如图 3 所示, 导致无法有效度量相同模式下数据的相似性。针对这种波形为动态对应而非一一对应的距离度量, 可使用动态时间弯曲方法(Dynamic time warping, DTW)进行计算。

3.1 动态时间弯曲

DTW 是一种相似性度量方式^[11], 最早应用于语音识别领域。DTW 以其非线性映射方面的优势, 最小化两个序列之间的距离来找到其最佳映射匹配^[12], 即使时间序列不规则或长度不一致, 亦可提供稳健的相似性或距离度量, 逐渐替代了传统的欧氏距离度量方法。

图 4 所示为欧氏距离与动态时间弯曲映射及匹配路径示意图。其中图 4a、4b 分别为欧氏和动态时间弯曲距离映射匹配方式, 图 4c 为两者的映射匹配路径, 表格中为序列 P 、 Q 对应数值差的平方。图中序列 $P=[1, 2, 4, 5, 6, 7, 6, 5, 4, 3]$, 序列 $Q=[0, 1, 1, 2, 3, 5, 6, 4, 3, 2]$ 。序列 P 、 Q 之间的欧氏距离为

$$Euclidean(P, Q) = \sqrt{1+1+9+9+9+4+0+1+1+1} = 6.0 \quad (4)$$

其匹配路径如虚线箭头所示。序列 P 、 Q 之间的动态时间弯曲距离如式(5)所示, 其匹配路径如实线箭头所示。

$$DTW(P, Q) = \sqrt{1+0+0+0+1+0+0+1+0+1+0+0+1} = 2.2 \quad (5)$$

从两者计算结果的对比可知, 对于波形相似但随时间轴伸缩或峰值不对应的时序数据, DTW 计算出的数据距离更为合理, 可有效度量数据的相似性。

图 4 欧氏距离与动态时间弯曲映射及匹配路径

3.2 样本综合距离度量

如前所述, 每个温度时间序列样本经构造后会得到相应的 v 、 v_minus 、 nor 三段数值序列, 本文采用式(6)计算两个时序样本之间的综合距离, 即

$$d_{con}(s_1, s_2) = \alpha \times dtw_v + \beta \times dtw_{v_minus} + \gamma \times dtw_{nor} \quad (6)$$

式中, $d_{con}(s_1, s_2)$ 表示样本 s_1 、 s_2 的综合距离; dtw_v 、 dtw_{v_minus} 、 dtw_{nor} 分别表示样本 s_1 、 s_2 利用式(1)、(2)、(3)构造得出的时间序列特征结果(如图 3 所示)的动态时间弯曲距离; α 、 β 、 γ 分别为相应时间序列特征, 即 v 、 v_minus 、 nor 对应的权重因子。

4 层次聚类算法

聚类是机器学习中的无监督学习方法^[13-14], 广泛应用于挖掘具有相似特征的数据集, 即根据数据对象的相似性将数据集划分为多个类簇。聚类后同一类簇中的数据对象之间的相似性较高, 不同类簇中的数据对象之间的相似性较低即差别较大^[15-16]。层次聚类^[17-18]是聚类算法的一个分支, 分为自下而上的凝聚型层次聚类 and 自上而下的分裂型层次聚类。自下而上的凝聚型层次聚类的基本思想是聚类开始时将每个样本作为单独的类簇, 然后计算各类簇彼此之间的距离, 随后将距离最小的两个类簇合并为一个类簇; 再次计算剩余所有类簇彼此之间的距离, 合并距离最小的两个类簇; 如此重复, 直到所有样本合并成为一个类簇为止。与凝聚型层次聚类相反, 自上而下的分裂型层次聚类在聚类伊始将所有样本归属为同一个类簇, 随后逐渐分裂该类簇, 直到所有的样本各自为簇, 或所分类簇个数达到预设的阈值为止。

鉴于黏结漏钢模式下温度时序特征相似性较高, 且与误报下的温度时序特征存在显著差异, 本文选择凝聚型层次聚类对两种模式下的温度时序特征进行提取。为此, 本文分别选用 30 例漏钢、50 例误报温度样本组成历史样本库 Q 作为训练集。对于漏钢温度样本, 标记黏结点临近电偶列第一排电偶温度最高时刻, 并选取该时刻的第一、二排前 15 s、后 10 s 共计 25 s 的温度数据; 对于误报温度样本, 截取任意连续 25 s 的第一、二排热电偶温度。随后利用式(1)~(3)构造其温度时序特征以组建训练数据集, 并分别取权重因子 $\alpha=0.25$ 、 $\beta=0.25$ 、 $\gamma=0.50$, 对训练数据集进行凝聚型层次聚类, 聚类结果如图 5 树状分支所示。图中标号为 1 的分支表示漏钢模式下的温度样本, 称之为漏钢类簇 C_B ; 标号为 2 的分支表示误报样本, 称之为正常工况类簇 C_N 。

从图 5 中可以看出, 由于黏结漏钢样本的温度时序特征彼此之间相似性较高、距离较小, 凝聚型层次聚类在聚类过程中可将漏钢模式下具有相似时序特征的样本合并为同一类簇 C_B , 且无一遗漏。同时, 由于与误报模式下的温度时序特征差异较大、相似性较低, 凝聚型层次聚类没有将任何误报样本

与漏钢样本合并,而是将误报模式下时序特征差异较大的样本划分为正常工况类簇 C_N 。此聚类结果印证了凝聚型层次聚类方法对辨识漏钢和误报模式下温度样本及其时序特征的有效性和适用性。

图5 训练样本集凝聚型层次聚类结果

5 基于聚类的黏结漏钢预报方法

基于图5所示的凝聚型层次聚类结果,设计和开发基于凝聚型层次聚类的黏结漏钢预报方法。首先,利用式(1)~(3)对获取的实时温度进行预处理,得到整体预处理结果以作为测试样本 x_{new} ;其次,将 x_{new} 与历史样本集 Q ,包括漏钢类簇 C_B 中的样本和正常工况类簇 C_N 中的样本,组成新的数据集,并对其实施凝聚型层次聚类;最后,根据 x_{new} 所在的类簇分支判定其是否属于漏钢。即,如果 x_{new} 位于漏钢类簇 C_B 所在分支,则认为 x_{new} 属于漏钢,随后采取降低拉速等相应措施;否则,认为 x_{new} 处于正常工况,更新温度序列,继续漏钢判断,判断流程如图6所示。

图6 基于凝聚型层次聚类的黏结漏钢预报方法设计流程

6 结果与讨论

为验证方法的有效性和准确性,利用建立模型对某钢厂近两年内漏钢预报系统报出的20例漏钢、100例误报数据进行测试。分别将每例测试样本的预处理结果与历史样本集 Q 进行聚类,如其属于漏钢类簇 C_B 分支,则判定为漏钢,否则为正常工况。

图7、8所示分别为测试样本中的2例误报和2例漏钢测试数据的第一、二排热电偶温度示意图。图中右侧垂直线表示在线检测时的当前时刻,左侧垂直线表示当前时刻之前的第24个时刻,两个垂直线之间表示所取的当前时刻及之前24s共计25s的温度数据。

图7 误报温度样本示意图

图8 黏结漏钢温度样本示意图

图7、8中误报和漏钢测试样本的聚类结果如图9、10所示。从图9和图10中可以看出,两例正常工况样本在聚类后均属于 C_N 分支,而两例漏钢测试样本在聚类后属于 C_B 分支。

(a)

图 9 误报测试样本聚类结果

图 10 黏结漏钢测试样本聚类结果

利用此方法对 120 例测试样本进行聚类 and 测试, 结果表明, 20 例漏钢测试样本聚类结束后均属于 C_B 分支, 真黏结的报出率为 100%。对于 100 例误报样本, 其中的 60 例判别为正常工况, 40 例错判为漏钢, 误报次数降低 60%。

为评估上述模型检测和识别黏结漏钢的准确性和有效性, 利用该方法对国内某钢厂宽厚板坯连铸机连续 7 个月的实测数据进行了测试和验证, 结果如表 1 所示。可以看出, 建立的模型能够准确报出所有的 13 例黏结漏钢, 与在线服役的漏钢预报系统相比, 74 次误报降低至 31 次, 误报次数降低了 58%。

基于以上测试结果, 无论是利用测试数据集, 还是连续一段时间的温度数据集, 方法可以有效区

分两种模式下典型的温度时序特征, 能够保证 100% 的真黏结报出率, 在避免真黏结漏报的前提下, 大幅降低了误报次数。

表 1 某钢厂一月~七月实测数据连续测试结果

时间	在线漏钢预报系统			本文所提方法		
	漏钢	误报	漏报	漏钢	误报	漏报
一月	3	10	0	3	4	0
二月	4	8	0	4	4	0
三月	2	11	0	2	5	0
四月	0	8	0	0	3	0
五月	2	26	0	2	11	0
六月	2	4	0	2	2	0
七月	0	7	0	0	2	0
总计	13	74	0	13	31	0

7 结论

现有的漏钢预报方法难以有效识别和剔除温度波动大、变化多样等不具有典型特征的温度模式进而导致频繁漏报甚至误报。针对这一问题, 本文尝试探索和开发基于聚类的结晶器黏结漏钢预报新方法。以未经人为干预的热电偶原始温度序列为输入, 从时间、空间角度构造包括温度、温度速率及时滞在内的完整、连续和联动特征, 利用凝聚型层次聚类和 DTW 度量数据序列的相似性, 提取黏结漏钢的共性特征并与正常工况相分离, 从而识别和预测结晶器黏结漏钢。经过与现场服役漏钢预报系统的测试和对比, 结果表明, 本文建立的方法在保证真黏结 100% 报出率的同时, 将误报次数降低了近 60%, 大幅提升了漏钢预报的准确性。基于聚类和距离度量的预报方法, 不需要人为设置预报参数和阈值, 且回避了制作训练样本的繁琐过程, 在连铸过程异常监控方面展现出极大的应用潜力。

参 考 文 献

- [1] 何飞, 吴鹏飞, 徐其言, 等. 连铸粘钢的结晶器温度变化及其传播行为[J]. 钢铁研究学报, 2016, 28(2): 27-32.
HE Fei, WU Pengfei, XU Qiyang, et al. Mould temperature change and propagation behavior of sticking-type breakout during continuous casting[J]. Journal of Iron and Steel Research, 2016, 28 (2): 27-32.
- [2] BLAZEK K, SAUCEDO I. Characterization of the formation, propagation, and recovery of sticker/hanger type breakouts[J]. ISIJ International, 1990, 30(6): 435-443.

- [3] LU M J, LIN K J, KUO C H, et al. Sticker breakout theory and its prediction in slab continuous-casting[C] // Proceedings of 67th Steelmaking Conference. MAR 28-31, Dallas TX: 67th Steelmaking Conference, 1993: 343-353.
- [4] ZHANG Y X, WANG W L, ZHANG H H. Development of a mold cracking simulator: The study of breakout and crack formation in continuous casting mold[J]. Metallurgical and Materials Transactions B, 2016, 47(4): 2244-2252.
- [5] HE F, ZHOU L, DENG Z H. Novel mold breakout prediction and control technology in slab continuous casting[J]. Journal of Process Control, 2015, 29: 1-10.
- [6] HE F, ZHANG L Y. Mold breakout prediction in slab continuous casting based on combined method of GA-BP neural network and logic rules[J]. International Journal of Advanced Manufacturing Technology, 2018, 95(9-12): 4081-4089.
- [7] LIU Y, WANG X D, DU F M, et al. Visual detection based on computer vision for sticker breakout in slab continuous casting[J]. Ironmaking & Steelmaking, 2015, 42(6): 417-423.
- [8] LIU Y, WANG X D, DU F M, et al. Computer vision detection of mold breakout in slab continuous casting using an optimized neural network[J]. International Journal of Advanced Manufacturing Technology, 2017 88(1-4): 557-564.
- [9] 刘宇, 王旭东, 姚曼, 等. 连铸结晶器黏结漏钢的可视化及其识别方法[J]. 钢铁研究学报, 2015, 27(7): 37-41.
LIU Yu, WANG Xudong, YAO Man, et al. Visualization and recognition method of sticker breakout of mold during continuous casting process[J]. Journal of Iron and Steel Research, 2015, 27(7): 37-41.
- [10] 刘宇, 王旭东, 施桂钱, 等. 宽厚板连铸黏结漏钢的工艺因素[J]. 北京科技大学学报, 2014, 36(6): 757-762.
LIU Yu, WANG Xudong, SHI Guiqian, et al. Process factors of sticking breakout for wide and thick slab continuous casting[J]. Journal of University Science and Technology Beijing, 2014, 36(6): 757-762.
- [11] BERNDT D J, CLIFFORD J. Using dynamic time warping to find patterns in time series[J]. KDD Workshop, 1994, 10(16): 359-370.
- [12] WAN Y, CHEN X L, SHI Ying. Adaptive cost dynamic time warping distance in time series analysis for classification[J]. Journal of Computational and Applied Mathematics, 2017, 319: 514-520.
- [13] JAIN A K. Data clustering: A review[J]. ACM Computing Surveys, 1999, 31(3): 264-323.
- [14] XU R, WUNSCH D. Survey of clustering algorithms[J]. IEEE Transactions on Neural Networks, 2005, 16(3): 645-678.
- [15] 高强, 向家伟, 汤何胜. 基于增强聚类分割与 L-峭度的 Teager 能量算子解调诊断轴向柱塞泵故障[J]. 机械工程学报, 2018, 54(18): 1-10.
GAO Qiang, XIANG Jiawei, TANG Hesheng. Axial piston pump fault diagnosis with Teager energy operator demodulation using improved clustering based segmentation and L-kurtosis[J]. Journal of Mechanical Engineering, 2018, 54(18): 1-10.
- [16] WANG L M, SHAO Y M. Crack fault classification for planetary gearbox based on feature selection technique and k-means clustering method[J]. Chinese Journal of Mechanical Engineering, 2018, 31(1): 242-252.
- [17] WARD J H. Hierarchical grouping to optimize an objective function[J]. Journal of the American Statistical Association, 1963, 58(301): 236-244.
- [18] SZEKELY G J, RIZZO M L. Hierarchical clustering via joint between-within distances: Extending Ward's minimum variance method[J]. Journal of Classification, 2005, 22(2): 151-183.

作者简介: 段海洋, 男, 1989 年出生, 博士研究生。主要研究方向为连铸过程异常监测。

E-mail: duanhaiyang@mail.dlut.edu.cn

王旭东(通信作者), 男, 1979 年出生, 博士, 教授, 博士研究生导师。主要研究方向为连铸过程模型化及质量控制。

E-mail: hler@dlut.edu.cn