



基于粒度聚类的铁矿石烧结过程运行性能评价

杜胜 吴敏 陈略峰 PEDRYCZ Witold

Operating Performance Assessment Based on Granular Clustering for Iron Ore Sintering Process

DU Sheng, WU Min, CHEN Lue-Feng, PEDRYCZ Witold

在线阅读 View online: <https://doi.org/10.16383/j.aas.c200267>

您可能感兴趣的其他文章

基于两层分块GMM-PRS的流程工业过程运行状态评价

Plant-wide Process Operating Performance Assessment Based on Two-level Multi-block GMM-PRS

自动化学报. 2019, 45(11): 2071-2081 <https://doi.org/10.16383/j.aas.2018.c170412>

基于分层分块结构的流程工业过程运行状态评价及非优原因追溯

Plant-wide Process Operating Performance Assessment and Non-optimal Cause Identification Based on Hierarchical Multi-block Structure

自动化学报. 2019, 45(2): 315-324 <https://doi.org/10.16383/j.aas.2017.c170159>

基于参考点预测的动态多目标优化算法

Dynamic Multi-objective Optimization Algorithm Based on Reference Point Prediction

自动化学报. 2017, 43(2): 313-320 <https://doi.org/10.16383/j.aas.2017.c150811>

一类工业运行过程多模型自适应控制方法

Multi-model Adaptive Control Method for a Class of Industrial Operational Processes

自动化学报. 2018, 44(7): 1250-1259 <https://doi.org/10.16383/j.aas.2017.c160763>

基于残差分析的混合属性数据聚类算法

Clustering Algorithm for Mixed Data Based on Residual Analysis

自动化学报. 2020, 46(7): 1420-1432 <https://doi.org/10.16383/j.aas.2018.c180030>

基于低密度分割密度敏感距离的谱聚类算法

Low Density Separation Density Sensitive Distance-based Spectral Clustering Algorithm

自动化学报. 2020, 46(7): 1479-1495 <https://doi.org/10.16383/j.aas.c180084>

基于粒度聚类的铁矿石烧结过程运行性能评价

杜胜^{1,2,3,4} 吴敏^{1,2,3} 陈略峰^{1,2,3} PEDRYCZ Witold⁴

摘要 烧结过程的运行性能是生产效率和能源利用的综合表现。运行性能评价是保持烧结过程的运行性能处于最优等级的前提。考虑到时间序列数据的冗余,提出一种基于粒度聚类的铁矿石烧结过程运行性能评价方法。首先,利用单因素方差分析方法选取影响运行性能等级的检测参数;然后,采用多粒度区间信息化实现检测参数时间序列数据的降维,并进行粒度聚类,得到聚类标签;最后,以聚类得到的聚类标签为输入,利用随机森林算法进行运行性能等级评价。利用实际钢铁企业的运行数据进行实验,构建两个对比实验,分别采用基于时间序列数据聚类(Time series data clustering, TSDC)方法和基于时间序列特征聚类(Time series feature clustering, TSFC)方法。实验结果表明,该方法为有效评价烧结过程的运行性能提供了一套可行方案,为操作人员提升烧结过程运行性能提供了有力的指导。

关键词 粒度聚类, 烧结过程, 时间序列, 运行性能

引用格式 杜胜, 吴敏, 陈略峰, Pedrycz Witold. 基于粒度聚类的铁矿石烧结过程运行性能评价. 自动化学报, 2023, 49(6): 1272–1282

DOI 10.16383/j.aas.c200267

Operating Performance Assessment Based on Granular Clustering for Iron Ore Sintering Process

DU Sheng^{1,2,3,4} WU Min^{1,2,3} CHEN Lue-Feng^{1,2,3} PEDRYCZ Witold⁴

Abstract The operating performance of the sintering process is about the comprehensive representation of production efficiency and energy utilization. The operating performance assessment is a prerequisite to maintain the operating performance of the sintering process at the optimal grade. By considering the redundancy of time series data, an operating performance assessment method based on granular clustering for the iron ore sintering process is presented in this paper. First, the one-way analysis of variance method is used to select the detection parameters that affect the operating performance grade. Then, the multi-granularity interval information granulation is used to achieve dimensionality reduction of the time series data for the detection parameters, and the granules are clustered to form the clustering labels. Finally, with labels obtained by clustering being the input, the random forest algorithm is used to assess the operating performance grade. Experiments are performed using the actual running data of iron and steel enterprises, and two comparative experiments are constructed using a method based on time series data clustering (TSDC) and a method based on time series feature clustering (TSFC), respectively. Results show that the proposed method provides a feasible scheme to assess the operating performance of the sintering process effectively, and provides powerful guidance for operators to improve the operating performance of the sintering process.

Key words Granular clustering, sintering process, time series, operating performance

Citation Du Sheng, Wu Min, Chen Lue-Feng, Pedrycz Witold. Operating performance assessment based on granular clustering for iron ore sintering process. *Acta Automatica Sinica*, 2023, 49(6): 1272–1282

收稿日期 2020-04-30 录用日期 2020-09-14

Manuscript received April 30, 2020; accepted September 14, 2020

国家自然科学基金(61210011), 湖北省自然科学基金(2015CFA010), 高等学校学科创新引智计划项目(B17040), 中国地质大学(武汉)中央高校基本科研业务费资助项目, 国家留学基金(201906410029)资助

Supported by National Natural Science Foundation of China (61210011), Hubei Provincial Natural Science Foundation (2015 CFA010), 111 Project (B17040), Fundamental Research Funds for National Universities, China University of Geosciences, and Program of China Scholarship Council (201906410029)

本文责任编辑 刘艳军

Recommended by Associate Editor LIU Yan-Jun

1. 中国地质大学(武汉)自动化学院 武汉 430074 中国 2. 复杂系统先进控制与智能自动化湖北省重点实验室 武汉 430074 中国 3. 地球探测智能化技术教育部工程研究中心 武汉 430074 中国

铁矿石烧结是人工富矿的主要途径,生成的烧 结矿是高炉冶炼的主要原料。烧结过程是一个包含 一系列复杂物理化学反应的热聚合过程,原料包括 铁矿粉、返矿、助熔剂和固体燃料(焦炭)^[1]。烧结过 程具有强非线性、强耦合性和大时滞性,这使得很

4. 阿尔伯塔大学电子与计算机工程系 埃德蒙顿 T6R 2V4 加拿大

1. School of Automation, China University of Geosciences, Wuhan 430074, China 2. Hubei Key Laboratory of Advanced Control and Intelligent Automation for Complex Systems, Wuhan 430074, China 3. Engineering Research Center of Intelligent Technology for Geoexploration, Ministry of Education, Wuhan 430074, China 4. Department of Electrical and Computer Engineering, University of Alberta, Edmonton T6R 2V4, Canada

难建立精确的烧结过程数学模型. 强非线性主要是由烧结过程中存在复杂的固相和液相反应^[2-3]导致的, 这些反应很难用数学关系描述. 强耦合性主要是指在生产过程中参数与参数之间存在耦合, 一个参数变化会导致一个或多个参数的联动^[4]. 大时滞性^[5]是指烧结过程耗时长, 参数的调节需要一段时间才能得到响应. 这些特性使得操作人员很难把控烧结过程的进度, 导致操作人员难以通过经验判断当前运行状态的好坏.

运行性能可用于衡量一段生产过程的运行状态, 它关系到烧结过程的生产效率和能源利用. 但是随着时间推移, 运行性能会偏离最优等级. 运行性能评价是将一段时间内的生产过程的运行性能划分为多个等级, 如优、良、一般、差等, 这本质上是一个时间序列的评价与分类问题. 运行性能评价是确保烧结过程的运行性能处于最优等级的前提. 运行性能评价不仅能指导操作人员控制烧结过程的高效运行, 而且为烧结过程运行性能提升奠定基础. 因此, 实现烧结过程的运行性能评价具有重要的经济价值.

对于工业过程运行性能的评价问题, 许多学者做出了贡献. Liu 等^[6]以综合经济指标预测为基础, 提出了一种运行性能评价方法. 文献^[7]提出了一种基于性能相似度的在线运行性能评估方法, 利用全潜结构投影模型提取数据中的变异信息, 为运行性能评价提供依据. 考虑多种工作模式、多种类信息源的工业过程特征, 如金湿法冶金过程, 学者们提出了分层分块评价结构的运行性能评估^[8-9]. 对于闭环控制下的工业过程中的运行性能, 学者们提出了一种同时进行的静态和动态评估方法^[10]. 为了评估具有少量历史数据的新建过程的性能, Zou 等^[11]提出了一种跨域特征转移学习评价方法.

虽然上述方法在一些特定的流程工业中得到了有效应用, 但是这些方法很难适用于烧结过程的运行性能评价问题. 烧结过程的运行性能评价主要是对烧结燃烧过程的评价. 烧结燃烧过程可以用烧结热状态的时间序列数据来描述. 烧结过程的运行性能评价是一个时间序列的评价与分类问题.

对于时间序列数据的评价与分类的研究主要可分为 3 类: 第 1 类是直接利用时间序列数据进行评价和分类, 如 Du 等^[12]直接利用时间序列数据进行聚类, 构建了烧结过程的工况识别方法; 第 2 类是对时间序列数据进行特征提取, 然后进行评价与分类, 如文献^[13]对时间序列数据进行几何特征提取, 用于电力系统的振荡识别; 第 3 类是对时间序列数据进行信息粒化, 然后进行评价与分类, 例如 Guo

等^[14]提出了时间序列数据的粒度模糊聚类方法, 用于时间序列分类.

信息粒是由(时间、空间、功能等)相似性(紧密度)而收集在一起的实体的集合^[15]. 对时间序列进行信息粒化, 不仅可以有效减少时间序列的信息冗余, 而且可以提取时间序列的动态特征^[16]. 烧结过程运行性能评价是对一段时间内的所有检测参数的时间序列数据进行评价. 由于运行性能评价的周期远大于传感器的检测周期, 而且很多检测参数在一定时间内是缓慢变化的, 短周期的采样会采集很多无用信息, 这导致了时间序列的信息冗余. 本文引入时间序列进行信息粒化, 提取烧结过程时间序列数据的动态特性, 进而实现烧结过程运行性能评价.

考虑到实际生产中对关键状态参数的边界约束, 本文引入田口过程能力指数作为烧结过程运行性能的衡量指标. 田口过程能力指数弥补了传统的过程能力指数, 只考虑工序平均值对规格中心的偏移的缺陷^[17]. 田口过程能力指数更完整地解释了质量特性偏离目标值的原因: 一是因为质量特性的波动, 二是因为工序平均值的偏移.

针对时间序列数据的冗余, 本文提出一种基于粒度聚类的铁矿石烧结过程运行性能评价方法. 首先, 该方法利用单因素方差分析方法选取运行性能评价所需的参数, 并利用多粒度区间信息粒化方法实现时间序列数据的降维; 然后, 结合随机森林算法进行运行性能等级评价; 最后, 利用实际钢铁企业的运行数据进行了实验. 实验结果表明, 该方法能有效评价烧结过程的运行性能, 能为操作人员提升烧结过程运行性能提供有力指导.

本文的创新点主要有以下 3 个方面: 1) 设计了烧结过程运行性能评价方案, 并通过参数选择、信息粒化和粒度聚类, 以及利用随机森林算法进行运行性能等级评价; 2) 采用时间序列的多粒度区间信息粒化方法处理烧结过程时间序列数据的冗余问题, 实现时间序列数据的降维; 3) 利用实际钢铁企业的运行数据, 对该方法的有效性进行了验证, 表明本文为烧结过程的运行性能评价提供了一套可行方案. 为便于阅读, 本文定义了相关符号说明如下:

T_{BTP}	烧结终点 (Burn-through point, BTP) 温度 ($^{\circ}\text{C}$)
L_{BTP}	烧结终点位置
T_i	第 i 个风箱废气温度 ($^{\circ}\text{C}$)
P_N	主风箱负压 (kPa)
H_M	料层厚度 (mm)
C_{pm}	田口过程能力指数
V_T	台车速度 (m/min)
P_i	第 i 个检测参数

L_i	第 i 个聚类标签
G_i	第 i 个运行性能等级
F_T	检验统计量
ρ	检验概率
X	时间序列
s_k	第 k 个时间序列片段
Ω_k	第 k 个信息粒
$\text{rep}(s_k)$	Ω_k 的数值代表
$\text{rep}(X)$	粒时间序列
c	聚类数目
C_i	第 i 个簇的聚类中心
u_{ij}	属于第 i 个簇的隶属度
$C_H(c)$	Calinski-Harabasz 系数

1 过程描述与评价方案设计

本节首先详细描述烧结矿的生产流程,并定义烧结过程的运行性能;然后,根据烧结过程的特性设计烧结过程运行性能评价方案.

1.1 烧结过程

本文以某钢铁企业 360 m² 的带式抽风烧结机为研究案例. 烧结工艺包括配料、混合制粒、布料点火、抽风烧结、破碎、冷却和筛分等工序. 烧结过程最重要的工序是抽风烧结,期间烧结混合料在抽风机的作用下自上而下燃烧,并随着烧结台车向机尾移动. 燃烧过程使烧结料层分成了原料带、燃烧带、干燥带、过湿带、熔融带和成品带,如图 1 所示.

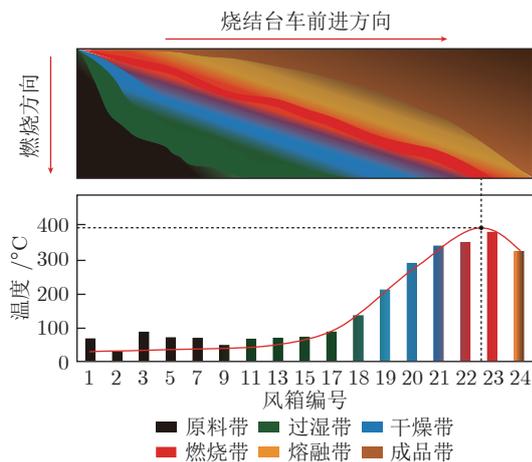


图 1 风箱废气温度和烧结带分布

Fig.1 Temperature of exhaust gas in bellows and sintering zone distribution

由于烧结料层中的温度无法直接测量,所以生产中通过检测风箱(共有 24 个风箱)中的废气温度来间接反映烧结料层的温度^[18]. 温度传感器分布在

1、2、3、5、7、9、11、13、15、17、18、19、20、21、22、23、24 号风箱里. 图 1 中最高的风箱废气温度被称为烧结终点温度 T_{BTP} (°C), 其对应的风箱位置称为烧结终点位置 L_{BTP} . 为了监视生产,除了检测燃烧过程的 17 个风箱废气温度 T_i , $i = 1, 2, \dots, 24$ (°C) 外,还检测主风箱负压 P_N (kPa)、料层厚度 H_M (mm) 和台车速度 V_T (m/min).

1.2 运行性能评价指标

为实现烧结过程运行性能的评价,需要构建合理的运行性能衡量指标. 在实际生产中,烧结终点是衡量烧结过程产量和质量的重要指标,它是烧结机上混合原料完全烧结的第 1 个位置,可表示为:

$$L_{BTP} = \int_0^T V_T(t) dt \quad (1)$$

式中, T 是指混合料烧透所用的时间. 一般认为 BTP 在倒数第 2 个风箱位置附近时,烧结过程产量最高,烧结矿质量最好. 如果 BTP 超前,则烧结机有效面积未充分利用,利用率较低;如果 BTP 滞后,那么在卸料时烧结料没有完全烧透,返矿增加,烧结矿产量较低.

由于 BTP 是具有一定范围要求的,可以引入过程能力指数来衡量一段时间内 BTP 的好坏. 过程能力指数是指工序在一定时间里处于控制状态下的实际加工能力,也是指满足产品质量标准要求的程度^[17]. 因此,本文以 BTP 作为决策参数,选择田口过程能力指数为烧结过程运行性能的评价指标.

对于一段 BTP 的时间序列数据, $L_{BTP} = [l_1, l_2, \dots, l_{m_L}]$, 其中 m_L 是时间序列段的长度,其田口过程能力指数^[17, 19] C_{pm} 表示为:

$$C_{pm} = \frac{l_U - l_L}{6\hat{\sigma}_L \sqrt{1 + \left(\frac{\hat{\mu}_L - l_T}{\hat{\sigma}_L}\right)^2}} \quad (2)$$

式中, l_U 是 BTP 的要求上限, l_L 是 BTP 的要求下限, l_T 是 BTP 的目标平均值. BTP 的波动要求是在 0.5 个风箱范围内. 因此, $l_U = l_T + 0.5$, 而 $l_L = l_T - 0.5$. $\hat{\mu}_L$ 是 L_{BTP} 的估计均值, $\hat{\sigma}_L$ 是 L_{BTP} 的标准差, 其中:

$$\hat{\mu}_L = \frac{1}{m_L} \sum_{i=1}^{m_L} l_i, \quad \hat{\sigma}_L = \sqrt{\frac{\sum_{i=1}^{m_L} (l_i - \hat{\mu}_L)^2}{m_L - 1}} \quad (3)$$

C_{pm} 值越大,表明 BTP 的离散程度相对于标准范围越小,烧结过程运行性能就越好; C_{pm} 值越小,表明 BTP 的离散程度相对标准范围越大,烧结

过程运行性能就越差. 因此, 可以从 C_{pm} 的数值大小来判断烧结过程的运行性能好坏. 根据文献 [20] 中 C_{pm} 的阈值设置, 可以得到运行性能等级划分, 如表 1 所示.

表 1 运行性能等级划分
Table 1 Operating performance grade division

运行性能等级	描述
优 (Perfect, Pe)	$C_{pm} \geq 1.67$
良 (Good, Go)	$1.67 > C_{pm} \geq 1.33$
一般 (General, Ge)	$1.33 > C_{pm} \geq 1.00$
差 (Poor, Po)	$1.00 > C_{pm} \geq 0.67$
不可接受 (Unacceptable, Un)	$0.67 > C_{pm}$

1.3 方案设计

烧结过程的运行性能评价问题是通过前一段时间的检测参数, 对烧结过程的运行性能进行评价, 得到运行性能等级. 运行性能评价可以提前获得烧结过程的运行状况, 这对操作人员控制烧结过程和提升运行性能具有重要的指导意义. 考虑到时间序列数据冗杂, 存在许多无用信息, 这会干扰运行性能评价的准确性. 因此, 本文设计了一种基于粒度聚类的烧结过程运行性能评价方案, 如图 2 所示.

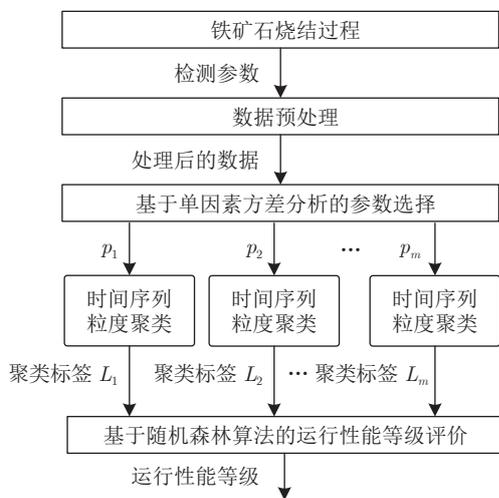


图 2 运行性能等级评价方案

Fig. 2 Scheme of operating performance grade assessment

首先, 利用传感器从烧结过程中获取检测参数的时间序列数据, 并对一些异常数据进行预处理; 然后, 利用单因素方差分析方法分析运行性能等级和检测参数的相关性, 确定对运行性能等级具有重要影响的检测参数 P_1, P_2, \dots, P_m , 其中 m 是选择的参数数量. 再分别对检测参数 P_1, P_2, \dots, P_m 的

时间序列数据进行信息粒化, 并进行粒度聚类, 得到聚类标签 L_1, L_2, \dots, L_m ; 最后, 以聚类标签为输入, 利用随机森林算法进行运行性能等级评价, 得到运行性能等级 (运行性能等级为 Pe、Go、Ge、Po 或 Un). 此评价方案通过粒度聚类将时间序列数据转换为标签数据, 以实现运行性能等级评价的目的.

在本方案中, 信息粒度指的是烧结过程中检测参数的时间序列数据由数字大小相似性聚集在一起的集合. 粒度聚类是将多粒度信息粒化后的粒时间序列进行聚类, 它的本质是从信息粒的角度衡量了运行性能的相似性. 聚类标签是对粒度聚类得到的不同粒时间序列集群的一个命名, 它表征着烧结过程运行性能较为相似情况下的粒时间序列的代表.

2 运行性能评价模型

本节将构建运行性能评价模型. 首先, 利用单因素方差分析方法进行参数选择; 然后, 利用多粒度区间信息粒化方法对时间序列数据进行信息粒化, 再利用模糊 c 均值 (Fuzzy c -means, FCM) 聚类方法得到聚类标签; 最后, 利用随机森林算法对聚类标签进行运行性能等级评价.

2.1 基于单因素方差分析的参数选择

本文需要分析的是检测参数是否对运行性能等级有显著影响, 这是一个连续变量和分类变量的相关性分析问题. 本文采用单因素方差分析方法进行参数选择. 单因素方差分析方法可以分析出在不同运行性能等级下检测参数数据分布的差异, 从而确定每个检测参数对运行性能等级是否有显著的影响. 虽然检测参数之间存在相互影响关系, 但是进行参数选择的目的是得到对运行性能等级具有显著影响的检测参数. 因此, 本文没有进行检测参数之间的相关性分析, 而是采用单因素方差分析方法实现检测参数与运行性能等级之间的相关性分析.

烧结过程有 5 个运行性能等级 $G_1, G_2, \dots, G_h, h = 5$. 以每个参数时间序列段内的平均值作为这段时间序列的代表, 这样就可以对每个运行性能中的参数分布情况进行分析. 假设有 N 个时间序列段, 属于 5 个运行性能等级的数目分布为 n_1, n_2, \dots, n_h . 那么等级 $G_j (j = 1, 2, \dots, h)$ 中的时间序列段可以表示为 $p_{1j}, p_{2j}, \dots, p_{n_jj}$. 等级 G_j 下的时间序列段平均值为:

$$\bar{p}_j = \frac{1}{n_j} \sum_{i=1}^{n_j} p_{ij} \quad (4)$$

时间序列数据的总平均值为:

$$\bar{p} = \frac{1}{N} \sum_{j=1}^h \sum_{i=1}^{n_j} p_{ij} = \frac{1}{n} \sum_{j=1}^h n_j \bar{p}_j \quad (5)$$

时间序列数据的总平方和为:

$$S_T = \sum_{j=1}^h \sum_{i=1}^{n_j} (p_{ij} - \bar{p})^2 \quad (6)$$

式中, S_T 反映了全部样本数据之间的差异, 其可分解为 $S_T = S_E + S_G$, 其中:

$$\begin{cases} S_E = \sum_{j=1}^h \sum_{i=1}^{n_j} (p_{ij} - \bar{p}_j)^2 \\ S_G = \sum_{j=1}^h \sum_{i=1}^{n_j} (\bar{p}_j - \bar{p})^2 = \sum_{j=1}^h n_j (\bar{p}_j - \bar{p})^2 \end{cases} \quad (7)$$

式中, S_E 为误差平方和, 表示在等级 G_j 下时间序列的观察值与平均值的差异, 是由随机误差所引起的. S_G 为等级 G_j 的效应平方和, 表示在等级 G_j 下的时间序列的平均值与总平均值的差异, 是由等级 G_j 以及随机误差所引起的.

当 S_G 与 S_E 相互独立时, S_G 与 S_E 分别服从自由度为 $h-1$, $N-h$ 的 χ^2 分布, 可以构造检验统计量 F_T :

$$F_T = \frac{\frac{S_G}{h-1}}{\frac{S_E}{N-h}} \sim F(h-1, N-h) \quad (8)$$

式(8)服从 F 分布. 可以计算在 F 分布中可以取大于 F_T 的检验概率 ρ ($F(h-1, N-h) \geq F_T$). 检验概率越小, 表示参数对运行性能等级的影响越大.

对烧结过程中的 20 个检测参数的 1000 个数据样本进行单因素方差分析, 并得到每个参数的检验概率, 如表 2 所示. 由表 2 可知, 参数 T_5 、 T_7 、 T_9 和 V_T 的检验概率明显大于其他参数. 图 3 列举了 4 个检测参数的相对于运行性能等级的数据箱图, 由图 3 可知, 参数 T_5 和 V_T 在各个运行性能等级上的分布差异不明显, 而 T_{18} 和 T_{24} 在不同运行性能等级下具有明显差异. 当 $\rho \leq 0.001$ 时, 认为检测参数对运行性能等级的影响是显著的. 那么可以选择出 $\rho \leq 0.001$ 的 16 个检测参数, 即得到 P_1, P_2, \dots, P_m , $m = 16$.

2.2 时间序列的粒度聚类

考虑到时间序列数据的冗余, 本节将先对检测参数 P_i ($i = 1, 2, \dots, m$) 的时间序列进行多粒度区间信息粒化, 以实现时间序列数据降维, 然后对

表 2 单因素方差分析结果

Table 2 Results of one-way analysis of variance

参数	ρ
T_1	6.76×10^{-8}
T_2	1.56×10^{-5}
T_3	8.26×10^{-5}
T_5	6.40×10^{-2}
T_7	1.90×10^{-2}
T_9	4.26×10^{-3}
T_{11}	2.47×10^{-25}
T_{13}	5.85×10^{-20}
T_{15}	6.43×10^{-20}
T_{17}	4.17×10^{-15}
T_{18}	9.39×10^{-25}
T_{19}	2.89×10^{-18}
T_{20}	1.84×10^{-21}
T_{21}	6.53×10^{-18}
T_{22}	3.59×10^{-20}
T_{23}	1.24×10^{-16}
T_{24}	2.35×10^{-35}
P_N	2.46×10^{-26}
H_M	1.46×10^{-13}
V_T	6.25×10^{-2}

形成的多粒度区间信息粒进行聚类.

多粒度区间信息粒化思想如图 4 所示. 首先, 将时间序列 $X = [x_1, x_2, \dots, x_{n_T}]$ (n_T 是时间序列长度) 分割成 n_s 个非重叠的时间序列片段 s_1, s_2, \dots, s_{n_s} ; 然后, 对每个时间序列片段 s_k 中的时间序列数据进行区间信息粒化得到 Ω_k , 并用数值代表 $\text{rep}(s_k)$ 表示. 通过这种方式, 原始时间序列 X 可以由 s_1, s_2, \dots, s_{n_s} 的数值代表来描述, 即 $\text{rep}(X) = [\text{rep}(s_1), \text{rep}(s_2), \dots, \text{rep}(s_{n_s})]$. 采用 $\text{rep}(X)$ 表示时间序列数据 X , 不仅降低了时间序列的维度, 同时保持了原始时间序列的动态特征.

时间序列片段 $s_k = [x_{i_k+1}, x_{i_k+2}, \dots, x_{i_k+j_k}]$, (j_k 是 s_k 的长度, i_k 是 s_k 在时间序列 X 中的起始索引) 的区间信息粒化, 是为 s_k 构建一个具有合理语义的信息粒 Ω_k . 合理粒度的原则使 Ω_k 应同时满足合理性和特殊性两个要求^[21]. 合理性要求 Ω_k 应尽可能地覆盖 s_k 中的时间序列数据点. 特殊性要求 Ω_k 应具有尽可能清晰的语义, 即 Ω_k 尽可能具体 (精细). 区间信息粒 $\Omega_k = [a_k, b_k]$ 覆盖时间序列数据点的个数为 $\text{card}\{x_t | x_t \in \Omega_k\}$, 可以量化信息粒的合理性. Ω_k 的长度 $m(\Omega_k) = |b_k - a_k|$, 可以量化信息粒的特殊性.

定义两个函数的乘积 $f = f_1 \cdot f_2$, 可以同时考虑合理性和特殊性, 其中 f_1 和 f_2 为:

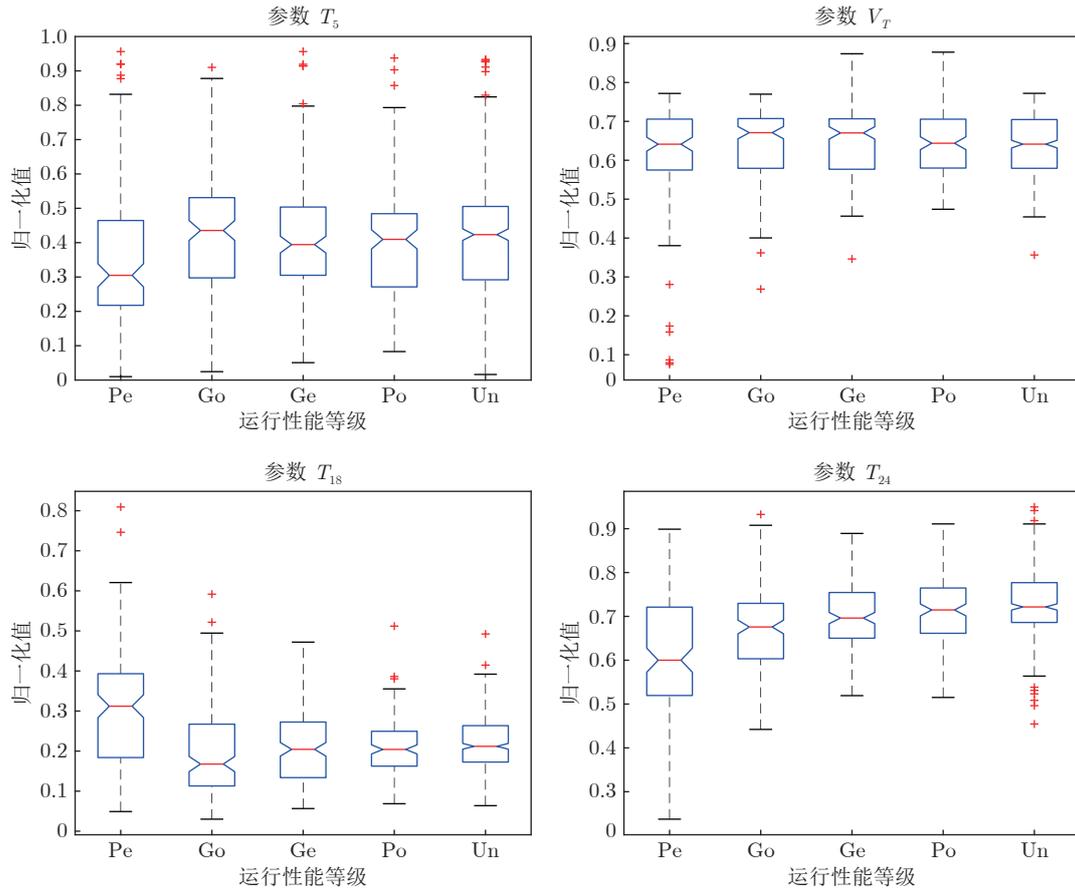


图 3 部分检测参数的数据箱图

Fig.3 Data box diagram of some detection parameters

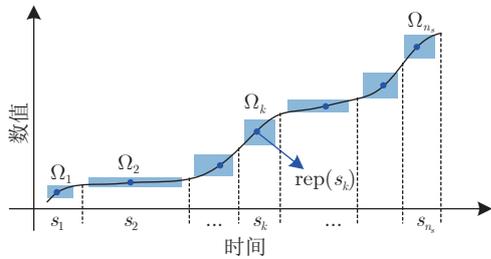


图 4 多粒度区间信息粒化

Fig.4 Multi-granular interval information granulation

$$\begin{cases} f_1 = \text{card} \{x_t | x_t \in \Omega_k\} \\ f_2 = \exp(-|b_k - a_k|) \end{cases} \quad (9)$$

设 $\text{rep}(s_k)$ 是 s_k 的数值代表 (平均值或中位数, 本文取中位数), 则可以基于函数 f 分别确定区间信息粒的下限 a_k 和上限 b_k :

$$\begin{cases} V(a_{k, \text{opt}}) = \max_{a_k \leq \text{rep}(s_k)} V(a_k) \\ V(b_{k, \text{opt}}) = \max_{b_k \geq \text{rep}(s_k)} V(b_k) \end{cases} \quad (10)$$

其中

$$V(a_k) = \text{card} \{x_t \in s_k | a_k \leq x_t \leq \text{rep}(s_k)\} \times \exp(-|\text{rep}(s_k) - a_k|)$$

$$V(b_k) = \text{card} \{x_t \in s_k | \text{rep}(s_k) \leq x_t \leq b_k\} \times \exp(-|b_k - \text{rep}(s_k)|)$$

通过上述方式, 可得到 s_k 的最佳区间信息粒 $\Omega_k =$

$$[a_{k, \text{opt}}, b_{k, \text{opt}}].$$

如图 4 所示, 将时间序列 X 分割为 n_s 个非重叠时间序列片段 s_1, s_2, \dots, s_{n_s} . 根据合理的粒度原理可为 s_k 形成合适的区间信息粒 $\Omega_k = [a_{k, \text{opt}}, b_{k, \text{opt}}]$. 这样时间序列 X 可以由多个区间信息粒 $\Omega_1, \Omega_2, \dots, \Omega_{n_s}$ 的集合表示. 多粒度区间信息粒化需要考虑信息粒的紧凑性^[14], 对于特定的 n_s , 最佳多粒度区间信息粒化是使所有信息粒的体积之和最小化的信息粒.

以 $m(\Omega_k) = |b_k - a_k|$ 和 s_k 的长度 T_k 的乘积表示区间信息粒 Ω_k 的体积, 即:

$$\text{Vol}(\Omega_k) = T_k \cdot m(\Omega_k) \quad (11)$$

所有信息粒 $\Omega_1, \Omega_2, \dots, \Omega_{n_s}$ 的体积之和为:

$$V = \text{Vol}(\Omega_1) + \text{Vol}(\Omega_2) + \cdots + \text{Vol}(\Omega_{n_s}) \quad (12)$$

式中, V 可以量化信息粒的紧凑性, 最佳多粒度区间信息粒化的目标是:

$$\min_{\Omega_1, \Omega_2, \dots, \Omega_{n_s}} \sum_{k=1}^{n_s} \text{Vol}(\Omega_k) \quad (13)$$

以式 (13) 为优化目标, Ω_k 为优化变量, 通过智能优化算法就可以得到最佳的多粒度区间信息粒. 本文采用粒子群优化算法, 实现最终的多粒度区间信息粒化.

通过多粒度区间信息粒化, 可将时间序列 X 转换为 $\text{rep}(X) = [\text{rep}(s_1), \text{rep}(s_2), \dots, \text{rep}(s_{n_s})]$, 进而实现了时间序列数据的降维. 为了实现运行性能评价的目的, 需要对降维后的粒时间序列进行聚类. 用聚类标签表示相似度高的一类粒时间序列, 可有效提高后续运行性能评价的精度. 对检测参数 P_i ($i = 1, 2, \dots, m$) 的时间序列进行粒度聚类, 是将多粒度区间信息粒化后的时间序列转化成了聚类标签 L_i ($i = 1, 2, \dots, m$). 本文采用模糊 c 均值聚类实现粒时间序列的聚类. FCM 聚类是用隶属度确定每个数据点属于某个聚类的程度的一种聚类算法^[2].

针对某个检测参数, 利用 FCM 聚类将 n_c 个粒时间序列 $\text{rep}(X_i)$, $i = 1, 2, \dots, n_c$ 分为 c 个簇, 就是求每个簇的聚类中心 C 和隶属度矩阵 U , 使得非相似性指标的价值函数达到最小. 隶属度矩阵 U 中元素的取值范围为 $(0, 1)$, 一个粒时间序列的隶属度的和总等于 1, 也就是 $\sum_{i=1}^c u_{ij} = 1, j = 1, 2, \dots, n_c$. FCM 聚类的目标函数定义为:

$$J(U, C) = \sum_{i=1}^c \sum_{j=1}^{n_c} u_{ij}^m \|\text{rep}(X_j) - C_i\|^2 \quad (14)$$

式中, u_{ij} 是 U 中的第 (i, j) 个元素, C_i 为第 i 个簇的聚类中心, $\|\text{rep}(X_j) - C_i\|^2$ 表示 C_i 与 $\text{rep}(X_j)$ 的欧氏距离, m 是一个加权指数. 目标函数表示考虑粒时间序列样本 $\text{rep}(X_j)$ 属于不同聚类的隶属度为 u_{ij} 的情况下, 所有 $\text{rep}(X_j)$ 到各个聚类中心 C_i 的距离之和. 目标函数越小, 表示聚类效果越好.

在约束条件 $\sum_{i=1}^c u_{ij} = 1$ 下, 要使目标函数 $J(U, C)$ 最小, 这是一个考虑约束的求极值问题. 采用拉格朗日乘数法构建新的目标函数:

$$L(U, C) = J(U, C) - \sum_{j=1}^{n_c} \lambda_j \left(\sum_{i=1}^c u_{ij} - 1 \right) \quad (15)$$

式中, λ_j 称为拉格朗日乘子. 上式分别对 u_{ij} 和 C_i 求导数, 可得使目标函数 $J(U, C)$ 最小的必要条件^[2]为:

$$C_i = \frac{\sum_{j=1}^{n_c} u_{ij}^m \text{rep}(X_j)}{\sum_{j=1}^{n_c} u_{ij}^m} \quad (16)$$

$$u_{ij} = \frac{1}{\sum_{k=1}^c \left(\frac{\|\text{rep}(X_j) - C_i\|}{\|\text{rep}(X_j) - C_k\|} \right)^{\frac{2}{m-1}}} \quad (17)$$

FCM 聚类算法是迭代计算式 (14)、式 (16) 和式 (17), 当目标函数小于某个确定的阈值或相对上次目标函数值的改变量小于某个阈值, 则算法停止. 检测参数的时间序列数据, 经过粒度聚类, 得到的聚类中心将应用于新的时间序列数据的聚类. 这样得到的聚类类别就是检测参数 P_i 时间序列转化后的聚类标签 L_i .

检测参数的聚类标签 L_i 是类别变量, 值域范围取决于聚类数目 c . 因此, 需要选择合适的 c , 以保证获得聚类标签能够有效代表原始的时间序列数据. 由于 FCM 聚类是自定义聚类数目, 因此引入 CH (Calinski-Harabasz) 系数^[24] 确定 FCM 聚类的聚类数目. CH 系数值用 C_H 表示, C_H 越高, 表示聚类效果越好, 定义如下:

$$C_H(c) = \frac{S_B}{S_W} \cdot \frac{n_c - c}{c - 1} \quad (18)$$

式中, S_B 表示簇之间距离的平方和, S_W 为每个时间序列与其所在簇聚类中心的距离的平方和. 每个簇的聚类中心为 C_i , 每个簇中时间序列个数为 n_i , 所有时间序列的中心为 \bar{X}_{rep} , S_B 和 S_W 可表示为:

$$\begin{cases} S_B = \sum_{i=1}^c n_i \|C_i - \bar{X}_{\text{rep}}\|^2 \\ S_W = \sum_{i=1}^c \sum_{j=1}^{n_i} \|\text{rep}(X_j) - C_i\|^2 \end{cases} \quad (19)$$

可见 S_W 越小, S_B 越大, 则聚类效果越好. $(n_c - c)/(c - 1)$ 表示 c 越大, C_H 值越小, 则聚类效果越差, 即 C_H 的目的是用尽量少的簇和尽量多的时间序列数据样本获得好的聚类效果.

2.3 运行性能等级评价

运行性能等级评价是找到当前检测参数的时间序列数据的运行性能等级, 也就是时间序列的分类问题. 通过时间序列的粒度聚类, 可以将检测参数的时间序列数据转化成聚类后的标签数据. 那么所涉及的运行性能等级评价转化为一个标签分类问题. 考虑到各个检测参数之间并非完全独立, 本文

采用随机森林算法来实现这些标签的分类. 文献 [25] 提出了一种同时分析静态和动态节点的增强型随机森林算法, 该方法着重于提取静态和动态节点以增强随机森林算法. 本文对时间序列降维并保留了时间序列的动态特性. 本文方法着重于对时间序列数据的处理.

设粒度聚类后的检测参数 P_i ($i = 1, 2, \dots, m$) 的时间序列被转化成了聚类标签 L_i ($i = 1, 2, \dots, m$). 那么运行性能等级评价模型可以表示为:

$$G = f_{\text{RF}}(L_1, L_2, \dots, L_m) \quad (20)$$

式中, G 的取值范围为 {Pe, Go, Ge, Po, Un}, $f_{\text{RF}}(\cdot)$ 表示随机森林分类器. 在构建运行性能评价模型时, 首先计算与检测参数时间序列数据相对应的烧结终点时间序列数据的田口过程能力指数, 并利用表 1 所示的运行性能等级划分方法, 得到检测参数时间序列数据所对应的运行性能等级; 然后利用检测参数时间序列数据和其对应的运行性能等级, 来训练运行性能评价模型.

随机森林算法通过自助法随机选择向量生长成分类“树”, 每个“树”都会完整生长而不会修剪. 并且在生成树的时候, 每个节点的变量都仅仅在随机选出的少数几个变量中产生. 最终的决策树是通过潜在的随机向量树进行“投票”表决生成的, 即随机森林选择具有最多投票的分类. 随机森林算法具有分类树的数量和分割节点的随机变量的数量两个非常重要的自定义参数. 通过对这两个参数进行优化, 使分类过程中错误出现的次数最小.

通过第 2.1 节 ~ 第 2.3 节介绍, 本文的运行性能评价方法流程可表示如下.

算法 1. 运行性能等级评价算法

输入. 某段时间内检测参数 T_i ($i = 1, 2, \dots, 24$), P_N 、 H_M 和 V_T 的时间序列数据.

输出. 运行性能等级 G {Pe, Go, Ge, Po, Un}.

1) 利用单因素方差分析方法, 选择显著影响运行性能等级的检测参数 P_1, P_2, \dots, P_m , $m = 16$;

2) 对检测参数 P_i ($i = 1, 2, \dots, m$) 的时间序列 X_i 进行多粒度区间信息粒化, 得到粒时间序列 $\text{rep}(X_i)$;

3) 对粒时间序列 $\text{rep}(X_i)$ 进行聚类, 得到 $\text{rep}(X_i)$ 对应的聚类标签 L_i ($i = 1, 2, \dots, m$);

4) 以聚类标签 L_i 为输入, 利用式 (20) 的随机森林分类器, 得到运行性能等级 G .

3 实验结果与分析

从某钢铁企业烧结厂收集了一个月的运行数据, 采样间隔为 5 s. 烧结机运行时会出现故障和停

机等情况, 这导致了原始数据存在很多噪声和检测误差. 因此对原始数据进行预处理是很有必要的. 经过滤波和剔除异常值等操作后, 将原始数据的采样间隔扩展到 30 s. 采样间隔的扩展既能减少数据量, 也保留了数据的变化特性.

首先, 需要验证信息粒化后的时间序列能否表征出原始时间序列的动态特征. 对烧结终点的时间序列数据进行了信息粒化的实验, 选择了长度为 50 的烧结终点时间序列样本, 时间间隔为 30 s; 然后, 利用本文提出的多粒度区间信息粒化方法, 对选取的烧结终点时间序列样本进行粒化, 设置信息粒的个数为 10. 最终得到了如图 5 所示的时间序列信息粒化结果. 由图 5 可以看出, 信息粒化后的时间序列能表征出原始时间序列的动态特征.

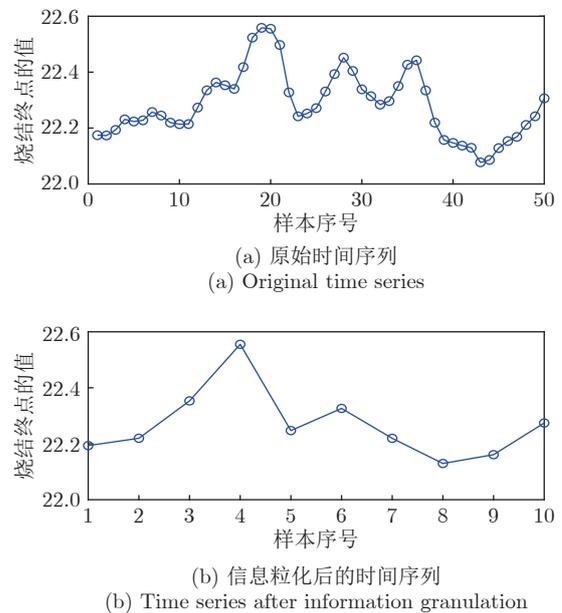


图 5 时间序列信息粒化结果

Fig. 5 Result of the information granulation of time series

一次完整的烧结过程大约需要 45 min. 为了对烧结过程进行更精细的评价, 选择运行性能评价的时间长度为 10 min, 也就是说需要评价的每个时间序列段有 20 个数据点. 对原始数据进行时间序列段分割, 得到 4000 组时间序列段. 实验采用十折交叉验证, 也就是将 4000 组时间序列段平均分成 10 个部分, 每次采用其中 9 个部分的时间序列段用作训练, 剩余部分的时间序列段用作测试. 依次不重叠地进行 10 次实验, 最后将实验结果进行累计.

为验证本文方法的有效性, 构建了对比实验. 本文的运行性能评价方法是基于时间序列粒度聚类 (Time series granular clustering, TSGC) 实现

的. 主要是考虑采用信息粒化来减少时间序列的冗余, 提取有效的信息. 设计的对比实验采用基于时间序列数据聚类 (Time series data clustering, TSDC)^[12] 的运行性能评价方法和基于时间序列特征聚类 (Time series feature clustering, TSFC)^[26] 的运行性能评价方法.

在基于 TSGC 方法中, 根据时间序列段长度设置每个时间序列粒化为 5 个区间信息粒. 对 4000 组时间序列段进行了 3 种聚类方法的测试, 设置了不同的聚类数目, 得到了聚类后的 CH 系数, 如图 6~8 所示. 图 6~8 可确定每个检测参数的最佳聚类数目 (图中最大值对应的聚类数目). 在随机森林算法进行运行性能等级评价中, 经网格法测试后选择分类树数量为 200, 分割节点数为 6. 基于 TSDC 方法直接使用时间序列数据进行聚类, 运行性能等级评价方法采用第 2.3 节所述方法. 基于 TSFC 的方

法采用时间序列的平均值和标准差两个特征来表示时间序列, 并进行聚类, 运行性能等级评价方法也采用第 2.3 节方法, 3 个实验的运行性能等级评价结果如表 3 所示. 表中数值指的是每个评价等级的查准率, 精度是指运行性能评价方法在 5 个评价等级的平均查准率.

图 6~8 列举了 4 个检测参数在不同聚类数目下的 CH 系数. 可以看出, 在 TSDC 和 TSGC 方法下的聚类效果是相似的, CH 系数和最佳聚类数目都很接近. 这反映了多粒度区间信息粒化是对时间序列的降维, 同时它保留了时间序列的动态特性. 由表 3 可以看出, 本文评价方法对于 Pe 和 Un 两个运行性能等级的评价精度相对较高, 而对其他运行性能等级的评价效果不佳, 这与数据的分布不均有一定关系. 此外还可以看出, 本文的 TSGC 方法能更有效地评价烧结过程的运行性能等级, 精度可达

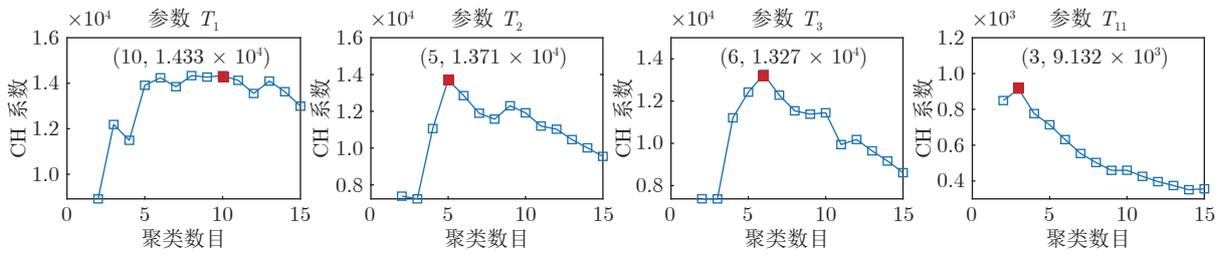


图 6 TSDC 得到的 CH 系数
Fig.6 The CH coefficient obtained by TSDC

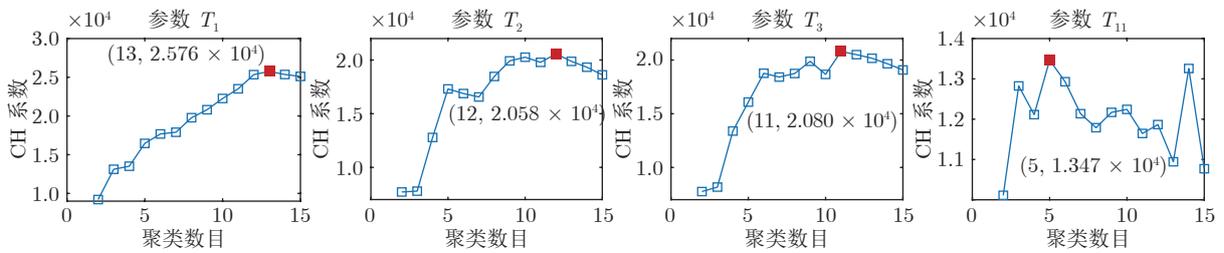


图 7 TSFC 得到的 CH 系数
Fig.7 The CH coefficient obtained by TSFC

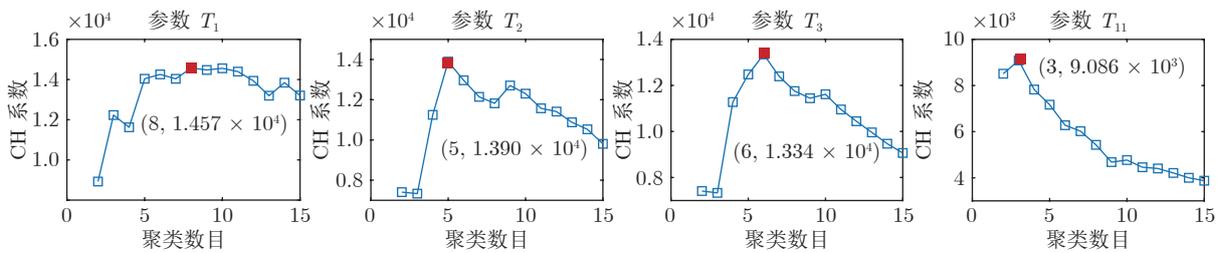


图 8 TSGC 得到的 CH 系数
Fig.8 The CH coefficient obtained by TSGC

表 3 运行性能评价结果 (%)
Table 3 Results of operating performance assessment (%)

评估等级	实际等级					精度	
	Pe	Go	Ge	Po	Un		
TSDC	Pe	89.08	7.96	1.20	0.70	1.06	79.70
	Go	8.97	75.41	9.21	3.38	3.03	
	Ge	4.58	8.50	66.45	13.73	6.75	
	Po	2.29	4.30	14.61	67.34	11.46	
	Un	1.53	4.81	5.03	8.10	80.53	
TSFC	Pe	90.08	7.08	1.20	0.64	0.99	80.28
	Go	8.84	75.55	8.96	3.90	2.76	
	Ge	4.43	9.09	67.63	11.31	7.54	
	Po	1.37	5.75	13.97	66.85	12.05	
	Un	1.22	4.22	5.22	8.10	81.24	
TSGC	Pe	94.24	5.04	0.14	0.36	0.22	83.40
	Go	8.35	79.52	10.41	1.37	0.34	
	Ge	0.44	12.66	67.03	12.45	7.42	
	Po	0	1.15	11.17	74.50	13.18	
	Un	0	0.54	5.59	11.60	82.28	

83.40%, 比 TSDC 方法提高了 3.70%, 比 TSFC 方法提高了 3.12%。TSFC 方法比 TSDC 方法也有一定程度的提升。这表明 TSGC 方法能降低时间序列数据的冗余, 同时提取有效信息。

4 结束语

针对烧结过程检测参数的时间序列数据冗余, 本文引入多粒度区间信息粒化实现时间序列数据的降维, 并保留时间序列的动态特征。在此基础上, 提出了一种基于粒度聚类的烧结过程运行性能评价方法。实验结果表明, 该方法相比传统的时间序列数据聚类 and 特征聚类方法, 能更有效评价烧结过程的运行性能等级, 可为操作人员控制烧结过程提供指导。

References

- Chen X, Lan T, Shi X, Tong C. A semi-supervised linear-nonlinear least-square learning network for prediction of carbon efficiency in iron ore sintering process. *Control Engineering Practice*, 2020, **100**: Article No. 104454
- Huang X, Fan X, Chen X, Gan M, Zhao X. Soft-measuring models of thermal state in iron ore sintering process. *Measurement*, 2018, **130**: 145–150
- Wang S, Li H, Zhang Y, Zou Z. A hybrid ensemble model based on ELM and improved AdaBoost.RT algorithm for predicting the iron ore sintering characters. *Computational Intelligence and Neuroscience*, 2019: Article No. 4164296
- Du S, Wu M, Chen X, Lai X, Cao W. Intelligent coordinating control between burn-through point and mixture bunker level in an iron ore sintering process. *Journal of Advanced Computational Intelligence and Intelligent Informatics*, 2017, **21**(1): 139–147
- Chen X, Shi X, Tong C. Multi-time-scale TFe prediction for iron ore sintering process with complex time delay. *Control Engineering Practice*, 2019, **89**: 84–93
- Liu Y, Wang F, Chang Y, Ma R. Comprehensive economic index prediction based operating optimality assessment and non-optimal cause identification for multi-mode processes. *Chemical Engineering Research and Design*, 2015, **97**: 77–90
- Liu Y, Chang Y, Wang F. Online process operating performance assessment and nonoptimal cause identification for industrial processes. *Journal of Process Control*, 2014, **24**(10): 1548–1555
- Zou Xiao-Yu, Wang Fu-Li, Chang Yu-Qing, Wang Min, Cai Qing-Hong. Plant-wide process operating performance assessment and non-optimal cause identification based on hierarchical multi-block structure. *Acta Automatica Sinica*, 2019, **45**(2): 315–324
(邹筱瑜, 王福利, 常玉清, 王敏, 蔡庆宏. 基于分层分块结构的流程工业过程运行状态评价及非优原因追溯. *自动化学报*, 2019, **45**(2): 315–324)
- Zou Xiao-Yu, Wang Fu-Li, Chang Yu-Qing, Zheng Wei. Plant-wide process operating performance assessment based on two-level multi-block GMM-PRS. *Acta Automatica Sinica*, 2019, **45**(11): 2071–2081
(邹筱瑜, 王福利, 常玉清, 郑伟. 基于两层分块 GMM-PRS 的流程工业过程运行状态评价. *自动化学报*, 2019, **45**(11): 2071–2081)
- Zou X, Zhao C. Concurrent assessment of process operating performance with joint static and dynamic analysis. *IEEE Transactions on Industrial Informatics*, 2020, **16**(4): 2776–2786
- Zou X, Wang F, Chang Y. Assessment of operating performance using cross-domain feature transfer learning. *Control Engineering Practice*, 2019, **89**: 143–153
- Du S, Wu M, Chen L, Cao W, Pedrycz W. Operating mode recognition of iron ore sintering process based on the clustering of time series data. *Control Engineering Practice*, 2020, **96**: Article No. 104297
- Cho H, Choi N, Lee B. Oscillation recognition using a geometric feature extraction process based on periodic time series approximation. *IEEE Access*, 2020, **8**: 34375–34386
- Guo H, Wang L, Liu X, Pedrycz W. Information granulation-based fuzzy clustering of time series. *IEEE Transactions on Cybernetics*, 2021, **51**(12): 6253–6261
- Pedrycz W, Bargiela A. Granular clustering: A granular signature of data. *IEEE Transactions on Systems, Man, and Cybernetics — Part B: Cybernetics*, 2002, **32**(2): 212–224
- Lu W, Chen X, Pedrycz W, Liu X, Yang J. Using interval information granules to improve forecasting in fuzzy time series. *International Journal of Approximate Reasoning*, 2015, **57**: 1–18
- Boyles R A. The Taguchi capability index. *Journal of Quality Technology*, 1991, **23**(1): 17–26
- Du S, Wu M, Chen L, Zhou K, Hu J, Cao W, et al. A fuzzy control strategy of burn-through point based on the feature extraction of time-series trend for iron ore sintering process. *IEEE Transactions on Industrial Informatics*, 2020, **16**(4): 2357–2368
- Wu C W. An efficient inspection scheme for variables based on Taguchi capability index. *European Journal of Operational Research*, 2012, **223**(1): 116–122
- Booker J M, Raines M, Swift K G. *Designing Capable and Reliable Products*. Oxford: Butterworth-Heinemann, 2001.
- Lu Wei. Time Series Analysis and Modeling Method Research Based on Granular Computing [Ph.D. dissertation], Dalian University of Technology, China, 2015
(卢伟. 基于粒计算的时间序列分析与建模方法研究 [博士论文], 大连理工大学, 中国, 2015)
- Wang W, Pedrycz W, Liu X. Time series long-term forecasting model based on information granules and fuzzy clustering. *Engineering Applications of Artificial Intelligence*, 2015, **41**: 17–24
- Bezdek J C, Ehrlich R, Full W. FCM: The fuzzy *c*-means clustering

tering algorithm. *Computers & Geosciences*, 1984, **10**(2-3): 191-203

- 24 Caliński T, Harabasz J. A dendrite method for cluster analysis. *Communications in Statistics-theory and Methods*, 1974, **3**(1): 1-27
- 25 Chai Z, Zhao C. Enhanced random forest with concurrent analysis of static and dynamic nodes for industrial fault classification. *IEEE Transactions on Industrial Informatics*, 2020, **16**(1): 54-66
- 26 Räsänen T, Kolehmainen M. Feature-based clustering for electricity use time series data. In: Proceedings of the 9th International Conference on Adaptive and Natural Computing Algorithms. Kuopio, Finland: 2009. 401-412



杜 胜 中国地质大学(武汉)自动化学院教授. 主要研究方向为复杂工业过程建模与控制.

E-mail: dusheng@cug.edu.cn

(**DU Sheng** Professor at the School of Automation, China University of Geosciences. His research interest

covers modeling and control of complex industrial processes.)



吴 敏 中国地质大学(武汉)自动化学院教授. 主要研究方向为过程控制, 鲁棒控制和智能系统. 本文通信作者. E-mail: wumin@cug.edu.cn

(**WU Min** Professor at the School of Automation, China University of Geosciences. His research interest

covers process control, robust control, and intelligent systems. Corresponding author of this paper.)



陈略峰 中国地质大学(武汉)自动化学院教授. 主要研究方向为智能系统, 模式识别和计算智能.

E-mail: chenluefeng@cug.edu.cn

(**CHEN Lue-Feng** Professor at the School of Automation, China University of Geosciences. His research

interest covers intelligent systems, pattern recognition, and computational intelligence.)



PEDRYCZ Witold 加拿大阿尔伯塔大学电子与计算机工程系教授. 主要研究方向为计算智能, 模糊建模, 粒度计算, 知识发现, 数据挖掘, 模糊控制和模式识别.

E-mail: wpedrycz@ualberta.ca

(**PEDRYCZ Witold** Professor in

the Department of Electronic and Computer Engineering, University of Alberta, Canada. His research interest covers computational intelligence, fuzzy modeling, granular computing, knowledge discovery, data mining, fuzzy control, and pattern recognition.)