

基于料面视频图像分析的高炉异常状态智能感知与识别

朱霖霖¹ 桂卫华^{1,2} 蒋朝辉^{1,2} 陈致蓬¹ 方怡静¹

摘要 智能感知、精准识别高炉 (Blast furnace, BF) 异常状态对高炉调控优化和稳定运行至关重要, 但高炉内部的黑箱状态致使传统检测方法难以直接感知并准确识别多种高炉异常状态. 新型工业内窥镜可获取大量料面视频图像, 为直接观测炉内运行状态提供了全新的手段. 基于此, 提出一种基于料面视频图像分析的高炉异常状态智能感知与识别方法. 首先, 提出基于多尺度纹理模糊 C 均值 (Multi-scale texture fuzzy C-means, MST-FCM) 聚类的高温煤气流区域提取方法, 准确获取煤气流图像, 并提取煤气流图像多元特征; 其次, 提出基于特征编码的高维特征降维方法, 结合自适应 K-means++ 算法, 实现煤气流异常状态的粗粒度感知; 在此基础上, 通过改进雅可比-傅立叶矩 (Jacobi-Fourier moments, JFM) 提取煤气流图像深层特征变化趋势, 进而提出细粒度煤气流异常状态感知方法; 最后, 基于煤气流异常状态感知结果, 结合料面视频图像, 提出多级残差通道注意力模块 (Multi-level residual channel attention module, MRCAM), 建立高炉异常状态识别模型 ResVGGNet, 实现高炉煤气流异常、塌料和悬料的精准在线识别. 实验结果表明, 所提方法能准确识别不同的高炉异常状态且识别速度快, 可为高炉平稳运行提供重要保障.

关键词 高炉, 料面图像, 高炉异常状态感知, 高炉异常状态识别, 多级残差通道注意力模块

引用格式 朱霖霖, 桂卫华, 蒋朝辉, 陈致蓬, 方怡静. 基于料面视频图像分析的高炉异常状态智能感知与识别. 自动化学报, 2024, 50(7): 1345–1362

DOI 10.16383/j.aas.c230674

Intelligent Perception and Recognition of Blast Furnace Anomalies via Burden Surface Video Image Analysis

ZHU Ji-Lin¹ GUI Wei-Hua^{1,2} JIANG Zhao-Hui^{1,2} CHEN Zhi-Peng¹ FANG Yi-Jing¹

Abstract The intelligent perception and precise recognition of blast furnace (BF) anomalies are important for BF regulation, optimization and stable operation. However, the opaque nature of the internal workings of the BF makes it difficult for traditional detection methods to directly perceive and accurately recognize various BF anomalies. The novel industrial endoscope can capture a large number of BF burden surface video images, providing a new way for direct observation of the furnace's operational status. Based on this, an intelligent perception and precise recognition method for BF anomalies is proposed via burden surface video image analysis. Firstly, a method for extracting high-temperature gas flow regions based on multi-scale texture fuzzy C-means (MST-FCM) clustering is proposed to accurately obtain gas flow images and extract multi-features of gas flow images. Secondly, a high-dimensional feature dimensionality reduction method based on feature encoding is proposed, which is combined with the adaptive K-means++ algorithm to achieve coarse-grained perception of gas flow anomalies. On this basis, a fine-grained perception method for gas flow anomalies is proposed by refining Jacobi-Fourier moments (JFM) to extract the deep feature change trend of gas flow images. Finally, based on the perception results of gas flow anomalies, and combined with BF video images, a multi-level residual channel attention module (MRCAM) is put forward and the BF anomalies recognition model ResVGGNet is established. This model achieves precise and online recognition of gas flow anomalies, collapsing and hanging burden surface in the BF. Experimental results demonstrate that the proposed method can accurately recognize different BF anomalies with a fast recognition speed, providing crucial assurance for the smooth operation of the BF.

Key words Blast furnace (BF), burden surface image, BF anomalies perception, BF anomalies recognition, multi-level residual channel attention module (MRCAM)

Citation Zhu Ji-Lin, Gui Wei-Hua, Jiang Zhao-Hui, Chen Zhi-Peng, Fang Yi-Jing. Intelligent perception and recognition of blast furnace anomalies via burden surface video image analysis. *Acta Automatica Sinica*, 2024, 50(7): 1345–1362

收稿日期 2023-11-01 录用日期 2024-02-29

Manuscript received November 1, 2023; accepted February 29, 2024

国家重大科研仪器研制项目 (61927803), 国家自然科学基金基础科学中心项目 (61988101), 国家自然科学基金 (62273359), 湘江实验室重大项目 (22XJ01005) 资助

Supported by National Major Scientific Research Equipment of China (61927803), National Natural Science Foundation of China Basic Science Center Project (61988101), National Natural Science

Foundation of China (62273359), and the Major Program of Xiangjiang Laboratory (22XJ01005)

本文责任编辑 孟凡利

Recommended by Associate Editor MENG Fan-Li

1. 中南大学自动化学院 长沙 410083 2. 湘江实验室 长沙 410205

1. School of Automation, Central South University, Changsha 410083 2. Xiangjiang Laboratory, Changsha 410205

高炉 (Blast furnace, BF) 炼铁过程作为现代钢铁制造的核心前端工序, 其保持稳定、高效、健康的运行状态对于钢铁企业稳定、安全运营至关重要^[1-2]. 高炉出现异常状态会导致原材料消耗增加、铁水质量不合格和停炉维护等问题, 进而带来巨大的资源浪费和经济损失, 甚至可能造成严重的生产事故和人员伤亡^[3-4]. 因此, 实时在线识别高炉炼铁过程异常状态是实现高炉冶炼过程全面监测和及时调控的前提, 也是保障高炉稳定运行的重要手段.

高炉是具有复杂物理化学反应的大型黑箱系统, 为保证高炉的稳定安全运行, 现有高炉异常状态监测方法主要分为四类: 机理模型法、专家系统法、基于运行过程数据的高炉异常状态识别方法 (数据驱动法) 和基于图像的高炉异常状态监测方法 (图像法). 机理模型法利用高炉动力学、传热学等学科知识建立描述高炉冶炼过程的理论模型, 如建立高炉整体炉热模型^[5]、高炉出铁口铁水出流模型^[6]、软融带模型^[7]等, 进而对高炉炉温向凉或向热进行定性判断. 这些模型极大地促进了研究者和操作人员对高炉内部运行情况的了解, 但高炉炼铁过程是一个极其复杂的分布式系统, 具有多变量耦合和非线性特性, 机理模型的建立往往涉及大量假设及简化, 难以准确反映高炉实际运行状态. 专家系统法通常根据高炉炼铁过程的工艺知识、高炉运行过程知识和高炉专家经验建立一系列规则, 通过模糊数学、模糊推理和决策方法进行高炉异常状态诊断^[8]. 但国内的高炉专家系统起步晚, 经验积累不足且高炉炉况受多种因素影响, 化验数据实时获取困难且检测数据存在噪声, 导致专家系统推断得到的信息可靠性较低. 其次, 建立有效的专家系统规则库需要高质量的铁矿石原料, 许多高炉难以满足该条件, 严重影响专家系统的应用有效性. 因此, 专家系统具有一定程度的缺陷. 数据驱动法通过利用与高炉异常状态标签相匹配的运行过程数据, 采用多元统计方法或机器学习、深度学习分析方法处理, 进而实现高炉异常状态监测. 多元统计方法主要利用偏最小二乘 (Partial least squares, PLS)^[9]、主成分分析 (Principal component analysis, PCA)^[9]、独立成分分析 (Independent component analysis, ICA)^[10]、典型相关分析 (Canonical correlation analysis, CCA)^[11] 和子空间分解^[12] 等不同的数学工具, 通过考虑运行过程数据的高斯性、动态性、非平稳性等不同特性, 得到更准确的控制限以达到对高炉异常状态检测的目的. 控制限来源于异常检测中的统计量, 以 T^2 (Hotelling's T-squared) 和 SPE

(Squared prediction error) 为主, 多元统计分析法通过计算相关统计量是否超过一定置信水平下的阈值判断高炉运行状态是否异常. 机器学习或深度学习利用 BP 神经网络^[13]、支持向量机^[14]、Ada-Boost^[15]、T-S 模糊神经网络^[16] 等机器学习工具或堆叠自编码器^[4]、深度置信网络^[17]、深度核网络^[18]、图神经网络^[19] 等深度学习手段, 对一段时间内大量运行过程数据与其对应的悬料、管道、正常高炉状态等标签进行端到端的学习. 但由于现场难以直接观察料面的情况, 悬料、管道等异常状态标签是由现场操作人员基于经验和对高炉运行过程数据的分析得到的. 塌料异常状态由于缺乏高炉专家的标签, 目前鲜有研究利用运行过程数据对其进行监测. 由于悬料、管道等高炉异常状态发生后, 对过程数据的影响有不同程度的滞后效应, 因此, 这些标签对应的高炉运行过程数据一般都是以时间段计算和分析的^[20-21]. 实际情况下, 塌料、煤气流异常等高炉异常状态是实时发生的, 依赖长时间运行过程数据的异常监测可能存在准确性低和时效性差的问题; 其次, 由于高炉运行过程数据变量存在动态时变性, 随着时间的推移, 运行过程数据的分布可能发生变化, 这可能导致在训练和测试阶段有效的数据驱动方法在实际应用中失效; 另外, 运行过程数据存在大量的缺失值、异常值, 数据驱动方法对数据预处理的依赖性强, 导致其对实时采集的高炉运行数据的泛化性能不佳. 基于图像的高炉异常状态监测方法研究较少, 主要集中于利用高炉炉顶红外图像监测高炉料面煤气流分布状态^[22], 或在高炉出铁口利用红外成像仪获取铁水流多元信息 (如铁水温度^[23]、流速^[24] 或流量^[25]) 间接判断高炉运行状态, 以及利用高炉风口回旋区图像对炉缸的活跃状态进行识别^[26]. 然而, 炉顶红外图像虽然可以获得炉顶煤气流的温度信息, 进而获得煤气流的分布状态, 但难以识别塌料、悬料等高炉异常状态; 而在出铁口和风口回旋区获得的图像, 可在一定程度上获取长期的高炉运行状态, 如高炉炉温向热、向凉和炉缸活跃状态等, 但难以获得炉顶发生的悬料、塌料、煤气流异常状态等高炉异常状态. 综上, 现有的高炉异常状态监测方法存在不同程度的缺陷.

为弥补现有方法存在的不足, 本文利用安装于高炉炉顶的新型工业内窥镜获取大量高炉料面图像, 对高炉煤气流异常、塌料和悬料进行实时在线监测. 但煤气流异常状态难以直接判断, 同时确保不同异常状态识别的准确性和实时性也极具挑战. 针对上述问题, 本文通过对高炉料面图像进行分析

与处理, 提出煤气流异常状态智能感知方法, 同时通过设计多级残差通道注意力模块 (Multi-level residual channel attention module, MRCAM), 提出高炉异常状态识别模型 ResVGGNet, 对异常煤气流、塌料和悬料进行准确实时识别. 本文的创新点总结如下:

1) 为准确获取高温煤气流区域, 本文将高炉料面图像的多尺度纹理信息与模糊 C 均值 (Fuzzy C-means, FCM) 方法结合, 提出多尺度纹理模糊 C 均值 (Multi-scale texture fuzzy C-means, MST-FCM) 方法, 能以无监督方式精确获得高温煤气流图像.

2) 为精确感知煤气流异常状态, 提出基于特征编码的高维特征降维方法. 结合自适应 K-means++ 算法, 实现煤气流异常状态的粗粒度感知. 基于此, 进一步提出基于改进雅可比-傅立叶矩 (Jacobi-Fourier moments, JFM) 的煤气流异常状态细粒度感知方法, 实现煤气流异常状态精细化感知.

3) 为同时确保高炉异常状态识别精度与速度, 通过设计多级残差通道注意力模块, 建立高炉异常状态识别模型 ResVGGNet. 实验结果表明, 所提方法在保证高识别精度的情况下, 识别速度快.

4) 本文首次利用高炉料面视频图像实现对高炉煤气流异常状态、塌料和悬料的实时在线监测, 为高炉不同异常状态识别提供新思路.

1 高温煤气流图像多元特征提取

如图 1(a) 所示, 新型工业内窥镜安装于高炉炉顶小坡度斜面上, 覆盖的高炉料面区域如图 1(b) 所示. 获得的高炉料面视频图像在经过图像增强^[27-28]等手段后, 如图 2 所示, 可清晰地看到中心区域不同形态的高温煤气流. 高炉煤气流初始分布位于风口回旋区, 自下而上穿过滴落带和软熔带到达块状带, 最后到达高炉炉顶料面区域, 形成料面高温煤气流. 高温煤气流的状态能直接反映炉内的运行状态正常与否^[29], 因此, 为捕捉煤气流异常状态变化, 本节首先精确提取高温煤气流图像, 随后定义并提

取高温煤气流图像多元特征 (Multi-features of gas flow images, MFGIs), 包括煤气流图像纹理特征、稳定性特征和煤气流形态特征.

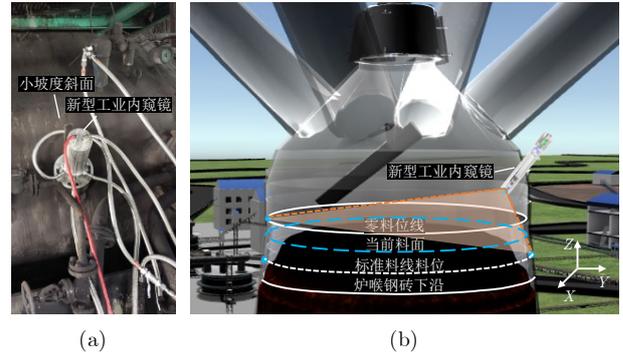


图 1 新型工业内窥镜安装示意图 ((a) 新型工业内窥镜实际安装位置; (b) 新型工业内窥镜成像区域示意图)
Fig.1 The schematic diagram of installation of the novel industrial endoscope ((a) Actual installation position of the novel industrial endoscope; (b) Schematic diagram of imaging area of the novel industrial endoscope)

1.1 基于 MST-FCM 的高温煤气流图像获取

图像的纹理具有方向性且沿不同方向纹理所包含的频率成分不同^[30]. 小尺度, 即图像的高频信息形成了图像的边缘和细节, 利用高频信息进行图像分割时, 分割准确度高, 但会受到噪声干扰; 大尺度, 即低频信息是图像的主要成分, 利用图像的低频信息进行图像分割虽然抗噪性强, 但准确度较低. 因此, 本文提出基于 MST-FCM 的高炉料面图像煤气流区域获取方法, 通过结合高频信息与低频信息的优势, 以达到更高的图像分割性能和噪声抵抗力.

对于尺寸为 $H \times W$ 的高炉料面图像 I , 为提取其多尺度信息, 利用二维小波变换获得高炉料面图像的小波分解子图, 具体为

$$\eta_1(x, y) = F_{LL}I \quad (1)$$

$$\eta_2(x, y) = F_{LH}I \quad (2)$$

$$\eta_3(x, y) = F_{HL}I \quad (3)$$

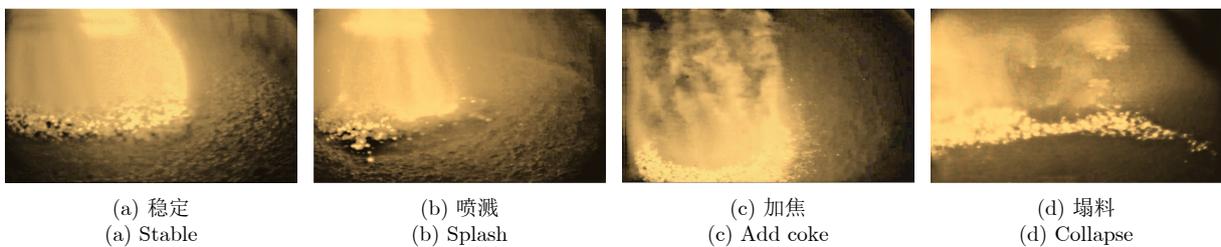


图 2 不同高炉运行状态下的高炉料面图像

Fig.2 BF burden surface images under different BF operation statuses

$$\eta_4(x, y) = F_{HHI} \quad (4)$$

其中, $\eta_1(x, y)$ 为原始高炉料面图像的低分辨率逼近子图, $\eta_{\text{sub}}(x, y)$, $\text{sub} = 2, 3, 4$ 分别为原始高炉料面图像的水平、垂直和对角线方向子图; F 为二维小波变换对应的滤波器。

选择合适的小波滤波器对于小波分解、纹理特征提取和图像分割至关重要. Haar 小波滤波器具有正交性、运算速度快和对称性等优势^[31], 特别适合离散图像处理. 因此, 本文选择 Haar 小波基作为二维小波变换的基础滤波器, 以保证分割速度和特征提取性能。

Haar 小波基的定义如下

$$\phi(x) = \begin{cases} 1, & 0 \leq x < 0.5 \\ -1, & 0.5 \leq x < 1 \\ 0, & \text{others} \end{cases} \quad (5)$$

将一维 Haar 小波变换推广到二维, 可得到其对应的四个滤波器分别为

$$F_{LL} = \begin{bmatrix} 1 & 1 \\ 1 & 1 \end{bmatrix}, \quad F_{LH} = \begin{bmatrix} -1 & -1 \\ 1 & 1 \end{bmatrix} \quad (6)$$

$$F_{HL} = \begin{bmatrix} -1 & 1 \\ -1 & 1 \end{bmatrix}, \quad F_{HH} = \begin{bmatrix} 1 & -1 \\ -1 & 1 \end{bmatrix} \quad (7)$$

为定量刻画各料面图像小波分解子图的多尺度纹理信息, 根据下式提取各子图的区域能量特征

$$\psi_{pp}(x, y) = \sum_{i=x-k}^{x+k} \sum_{j=y-k}^{y+k} \eta_{pp}^2(i, j) \quad (8)$$

其中, $pp = 1, 2, 3, 4$, i 和 j 表示子图中的像素位置, k 是所选择的能量计算区域模板大小, 本文选择 $k = 3$ 。

高炉料面图像在像素 (x, y) 处的能量特征 $\zeta_{x, y}$ 由四个不同子图的能量特征共同构成

$$\zeta_{x, y} = [\psi_1(x, y), \psi_2(x, y), \psi_3(x, y), \psi_4(x, y)] \quad (9)$$

因此, 高炉料面图像多尺度纹理特征矩阵 Υ 可表示为

$$\Upsilon = \begin{bmatrix} \zeta_{11} & \zeta_{12} & \cdots & \zeta_{1W} \\ \zeta_{21} & \zeta_{22} & \cdots & \zeta_{2W} \\ \vdots & \vdots & \ddots & \vdots \\ \zeta_{H1} & \zeta_{H2} & \cdots & \zeta_{HW} \end{bmatrix} \quad (10)$$

为在降低纹理特征矩阵大小的同时, 最大程度保留图像特征, 采用最大池化方式对特征矩阵 Υ 进行压缩. 高炉料面图像的尺寸为 $H \times W$, 因此多尺

度纹理特征矩阵 Υ 的维度为 $H \times W \times 4$. 在进行压缩时, 为最大程度保留纹理信息并加快运算速度, 选择 2×2 的卷积核. 压缩后的多纹理特征矩阵可表示为

$$\Phi = \begin{bmatrix} \varphi_{11} & \varphi_{12} & \cdots & \varphi_{1\frac{W}{2}} \\ \varphi_{21} & \varphi_{22} & \cdots & \varphi_{2\frac{W}{2}} \\ \vdots & \vdots & \ddots & \vdots \\ \varphi_{\frac{H}{2}1} & \varphi_{\frac{H}{2}2} & \cdots & \varphi_{\frac{H}{2}\frac{W}{2}} \end{bmatrix} \quad (11)$$

由于高炉内部缺少充足的光照, 通过高温工业内窥镜获得的高炉料面图像质量通常较低, 并且常出现光照极其不均匀的情况. FCM 聚类分析法通过使用隶属度来描述图像像素之间的模糊程度^[32], 能够在聚类过程中达到较好的效果, 特别适合于原始图像清晰度不高的高炉料面图像的像素聚类与分割, 因此, 也同样适用于特征矩阵的聚类分析。

MST-FCM 的目标函数可表示为

$$J_{\text{FCM}} = \sum_{i=1}^n \sum_{j=1}^c u_{ji}^m d^2(\varphi_i, v_j) \quad (12)$$

其中, φ_i 为压缩特征矩阵元素; n 为料面图像中的像素个数; c 为聚类数目, 对于料面高温煤气流区域获取而言, c 为 2; m 是每个模糊隶属度上的加权指数且其值大于 1, 一般取值为 1.5 ~ 2.5; u_{ji} 是压缩特征矩阵元素 φ_i 在簇中心 v_j 中的隶属度; $d(\varphi_i, v_j)$ 为压缩特征矩阵元素与簇中心 v_j 之间的距离度量, 并且隶属度 u_{ji} 满足

$$\sum_{j=1}^c u_{ji} = 1 \quad (13)$$

为求得在约束 (13) 下目标函数 (12) 的最小值, 利用拉格朗日乘数法构建新的目标函数

$$f(\varphi_i, u_{ji}, v_j) = \sum_{i=1}^n \sum_{j=1}^c u_{ji}^m d^2(\varphi_i, v_j) + \sum_{i=1}^n \alpha_i \left(1 - \sum_{j=1}^c u_{ji} \right) \quad (14)$$

对 (14) 分别求 u_{ji} , v_j 和 α_i 的偏导数, 并令各自偏导等于 0, 可得式 (15) 所示的聚类中心和式 (16) 所示的隶属度。

通过对式 (15) 和式 (16) 进行迭代计算求解, 可得到最终的聚类中心和隶属度. 迭代步骤如下:

步骤 1. 设定聚类数 c 、加权指数 m 、误差控制项 δ 和最大迭代次数 τ 的初值;

步骤 2. 随机初始化聚类中心及模糊隶属度矩

阵 $u^{(0)}$;

步骤 3. 设置循环次数 $k = 0$;

步骤 4. 在第 k 步时, 利用 $u^{(k)}$ 根据式 (15) 计算聚类中心 $v^{(k)}$

$$v_j^{(k)} = \frac{\sum_{i=1}^n (u_{ji}^{(k)})^m \varphi_i}{\sum_{i=1}^n (u_{ji}^{(k)})^m} \quad (15)$$

步骤 5. 计算 $u^{(k+1)}$

$$u_{ji}^{(k+1)} = \frac{\sum_{r=1}^c (d(\varphi_i, v_r))^{-\frac{2}{m-1}}}{\sum_{r=1}^c (d(\varphi_i, v_j))^{-\frac{2}{m-1}}} \quad (16)$$

步骤 6. 如果 $\|u^{(k+1)} - u^{(k)}\| < \delta$, 则执行步骤 7, 否则 $k = k + 1$, 并执行步骤 4 ~ 6;

步骤 7. 输出最终的隶属度矩阵和聚类中心;

步骤 8. 采用步骤 7 获得的聚类中心和隶属度矩阵对原始高炉料面图像进行 FCM 聚类, 从而快速、准确分割高炉料面图像.

利用所提 MST-FCM 方法、传统的 FCM 方法和先进的 SA (Segment anything)^[33] 最终获取的高温煤气流图像如图 3 所示. 相比传统的 FCM 方法, 本文所提 MST-FCM 方法提取的高温煤气流区域更准确. 如图 3(c) 所示, SA 方法对图像的分割过细, 导致难以符合煤气流的实际运动情况, 所提取的煤气流边缘也不连续. 本文所提的 MST-FCM 方法能够对不同形态的煤气流区域均准确地获取高温

煤气流图像, 展现了其在高温煤气流图像提取方面的优越性能.

1.2 高温煤气流图像纹理特征提取

如图 3 所示, 不同状态下高温煤气流图像纹理与形态均存在不同. 为定量描述煤气流状态, 本文基于灰度共生矩阵^[34] 定义煤气流图像纹理特征, 用于表征煤气流状态, 同时定义新的纹理稳定性特征.

设高温煤气流灰度图像 $I_g(x, y)$ 的灰度级数为 η , 在该灰度级数下某一像素 (x, y) 的灰度值为 i , 另一像素 $(x + a, y + b)$ 的灰度值为 j , 统计该两个像素的灰度值对 (i, j) 在原灰度图像中出现的次数 $P_{a, b}(i, j)$, 由式 (17) 表示, 从而构成 $\eta \times \eta$ 维高温煤气流纹理矩阵 G

$$P_{a, b}(i, j) = \sum \sum \Xi(i, j) \quad (17)$$

其中

$$\Xi(i, j) = \begin{cases} 1, & I_g(x, y) = i, I_g(x + a, y + b) = j \\ 0, & \text{否则} \end{cases}$$

W 和 H 分别是图像的宽度和高度. 这两个像素的位置可确定像素对的四个移动方向 θ , 如下式所示

$$\theta = \begin{cases} 0^\circ, & a > 0, b = 0 \\ 45^\circ, & a = b > 0 \\ 90^\circ, & a = 0, b > 0 \\ 135^\circ, & a = -b < 0 \end{cases} \quad (18)$$

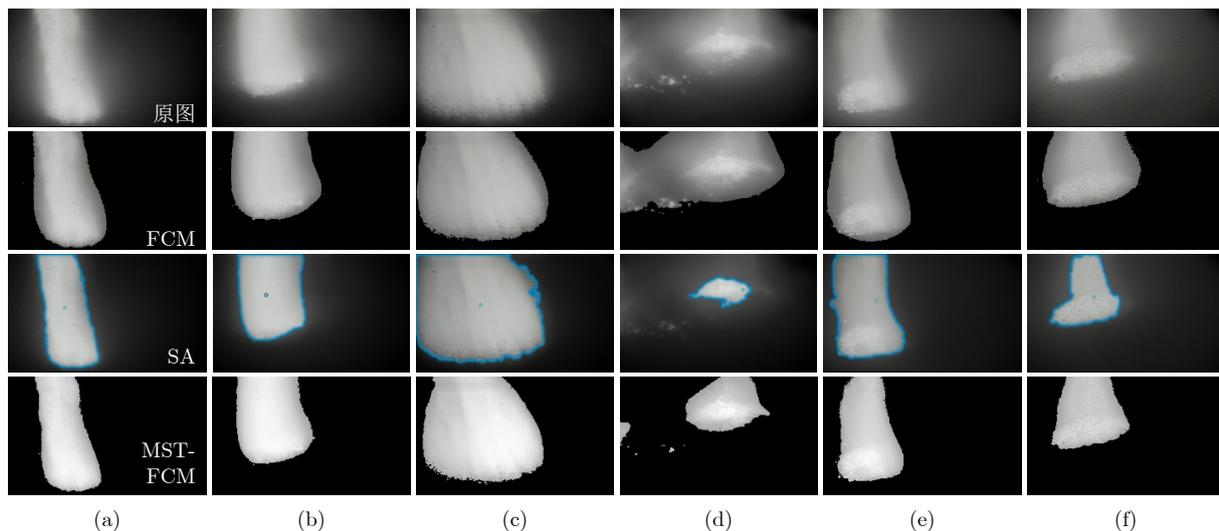


图 3 不同炉况下不同方法获取高温煤气流图像对比结果 ((a) 稳定 1; (b) 稳定 2; (c) 煤气流状态异常; (d) 悬料 1; (e) 悬料 2; (f) 高料位)

Fig. 3 Comparison results of high temperature gas flow images acquired by different methods under different BF conditions ((a) Stable 1; (b) Stable 2; (c) Abnormal gas flow status; (d) Hanging 1; (e) Hanging 2; (f) High stockline)

对于灰度等级为 0 ~ 255 的高炉料面灰度图像, 生成的高温煤气流纹理矩阵维度太大, 因此需要对其灰度等级进行压缩. 但压缩太大难以保留足够的信息, 压缩过小难以达到缩小运算量的目的. 本文将原灰度值压缩至 0 ~ 15, 保证信息保留的同时, 又缩减了大量的运算量, 提升了计算效率.

为更直观描述高温煤气流图像纹理特征, 在此基础上, 获取煤气流图像纹理矩阵的二次统计量. 本文选取五种互无相关性的特征, 分别为能量、对比度、图像熵、自相关性和同质性, 同时定义新的稳定性特征.

高温煤气流图像的能量 G_{ASM} , 也称为角二阶矩, 如式 (19) 所示, 其表示火焰区域分布的均匀程度和纹理的粗细程度, 可间接反映状态波动情况. 其值越小, 说明煤气流图像纹理矩阵元素的值越接近, 状态越稳定; 反之, 说明状态越不稳定.

$$G_{ASM}(i, j, \theta) = \sum_{i=0}^{\eta} \sum_{j=0}^{\eta} P^2(i, j, \theta) \quad (19)$$

其中, $P(i, j, \theta)$ 表示在角度 θ 下像素对 (i, j) 出现的频次, 如式 (17) 所示.

高温煤气流图像的对比度 G_{CON} , 如式 (20) 所示, 反映了煤气流火焰图像的清晰度, 也反映了状态的稳定情况. 其值越大, 煤气流火焰图像越清晰, 则状态越稳定; 反之, 其值越小, 煤气流火焰图像越模糊, 则状态波动越大.

$$G_{CON}(i, j, \theta) = \sum_{i=0}^{\eta} \sum_{j=0}^{\eta} (i - j)^2 P(i, j, \theta) \quad (20)$$

高温煤气流图像的熵 G_{ENT} , 如式 (21) 所示. 其反映了图像内容的随机性, 其值越大表明纹理越复杂, 则状态越不稳定; 反之, 纹理越简单, 状态越稳定.

$$G_{ENT}(i, j, \theta) = - \sum_{i=0}^{\eta} \sum_{j=0}^{\eta} P(i, j, \theta) \log_2 P(i, j, \theta) \quad (21)$$

高温煤气流图像的同质性 G_{HIOM} , 又称为逆方差, 如式 (22) 所示. 其反映了纹理局部变化的大小, 若图像纹理的不同区域间较均匀, 则同质性较大, 状态比较稳定; 反之, 状态不稳定.

$$G_{HIOM}(i, j, \theta) = \sum_{i=0}^{\eta} \sum_{j=0}^{\eta} \frac{P(i, j, \theta)}{1 + (i - j)^2} \quad (22)$$

高温煤气流图像的自相关性 G_{COR} , 如式 (23) 所示, 表征煤气流图像纹理矩阵在行或列方向上的相似程度, 其值的大小反映了图像局部灰度的相关性. 若煤气流图像纹理矩阵中的元素值均匀时, 相

关值大, 则状态比较稳定; 反之, 则状态不稳定.

$$G_{COR}(i, j, \theta) = \frac{\sum_{i=0}^{\eta} \sum_{j=0}^{\eta} (i \times j) P(i, j, \theta) - \mu_x \mu_y}{\sigma_x \sigma_y} \quad (23)$$

其中

$$\mu_x = \sum_{i=0}^{\eta} \sum_{j=0}^{\eta} i \times P(i, j, \theta) \quad (24)$$

$$\mu_y = \sum_{i=0}^{\eta} \sum_{j=0}^{\eta} j \times P(i, j, \theta) \quad (25)$$

$$\sigma_x^2 = \sum_{i=0}^{\eta} \sum_{j=0}^{\eta} (i - \mu_x)^2 P(i, j, \theta) \quad (26)$$

$$\sigma_y^2 = \sum_{i=0}^{\eta} \sum_{j=0}^{\eta} (j - \mu_y)^2 P(i, j, \theta) \quad (27)$$

由于高温煤气流图像具有一定的方向和纹理结构, 因此, 本文针对高温煤气流纹理稳定性, 定义了新的特征, 如式 (28) 所示. 纹理稳定性特征越大, 说明高温煤气流区域越稳定, 状态就越稳定.

$$G_{Trace}(i, j, \theta) = \sum_{i=0}^{\eta} P_N(i, j, \theta) \quad (28)$$

其中, $P_N(i, j, \theta)$ 是归一化的高温煤气流图像纹理矩阵, 具体为

$$P_N(i, j, \theta) = \frac{P(i, j, \theta)}{\sum_{i=0}^{\eta} \sum_{j=0}^{\eta} P(i, j, \theta)} \quad (29)$$

1.3 高温煤气流图像形态特征提取

高温煤气流图像的几何图像矩可直接表征其形态特征. 这些几何图像矩代表高温煤气流的面积、质心、煤气流倾斜度、伸展均衡度和轮廓细节等低层次特征.

高温煤气流图像由在点 (x, y) 处的亮度值 f 构成, 因此可看成一个二维密度分布 $f(x, y)$. 具体而言, 高温煤气流图像 $f(x, y)$ 的 $p + q$ 阶几何图像矩定义为

$$m_{pq} = \sum_x \sum_y x^p y^q f(x, y), \quad p, q = 0, 1, 2, \dots \quad (30)$$

不同阶数的几何图像矩表示不同的低层特征. 图像的零阶几何矩表示图像的像素总和, 即图像的面积; 一阶几何矩表示图像的质心. 质心 (x_0, y_0) 可由零阶矩和一阶矩共同计算

$$x_0 = \frac{m_{10}}{m_{00}}, y_0 = \frac{m_{01}}{m_{00}} \quad (31)$$

图像 $f(x, y)$ 的 $p+q$ 阶中心矩是以质心为中心矩, 定义为

$$u_{pq} = \sum_x \sum_y (x - x_0)^p (y - y_0)^q f(x, y) \quad (32)$$

其中, $p, q = 0, 1, 2, \dots$

利用二阶中心矩可以计算得到图像的协方差矩阵

$$\text{Cov}(f) = \frac{1}{u_{00}} \begin{bmatrix} u_{20} & u_{11} \\ u_{11} & u_{02} \end{bmatrix} \quad (33)$$

图像区域的方向可通过协方差矩阵最大特征值对应的特征向量计算得到

$$\theta = \frac{1}{2} \arctan \left(\frac{2u_{11}}{u_{20} - u_{02}} \right) \quad (34)$$

高层次特征可用高阶几何图像矩表示. 三阶矩是图像感兴趣区域轮廓细节及低阶矩变化的具体表现. 三阶矩包括 m_{30} , m_{03} , m_{21} 和 m_{12} 四种不同的形式. 其中, m_{30} 和 m_{03} 表示图像质心的位置偏移中心位置的情况; m_{21} 和 m_{12} 表示目标区域的伸展均衡度.

2 煤气流异常状态智能感知与高炉异常状态识别方法

针对高炉煤气流异常状态离线感知难的问题, 本文基于煤气流图像多元特征, 提出高炉异常状态智能感知方法. 首先, 提出基于特征编码的高维特征降维方法, 结合自适应 K-means++ 算法, 实现煤气流异常状态的粗粒度感知; 基于此, 进一步提出基于改进雅可比-傅立叶矩的细粒度煤气流异常状态感知方法, 实现煤气流异常状态精细化感知; 最后, 基于精细化感知结果, 设计 MRCAM, 并建立 ResVGGNet 模型用于高炉异常状态在线识别. 本文所提方法的总体框架如图 4 所示.

2.1 煤气流异常状态粗粒度感知方法

2.1.1 基于特征编码的高维特征降维方法

煤气流图像多元特征的维度过高会导致特征样本在空间上分布稀疏, 同时数据维度太多难以分析且会导致后续的 MFGIs 聚类处理效率较低, 因此需要对 MFGIs 进行降维处理, 减少其中冗余信息和噪声带来的误差, 提高后续聚类的精度, 同时也能更好地可视化. 通过这种方式, 能够有效处理和分析高维数据, 提升后续聚类 and 异常状态感知的效

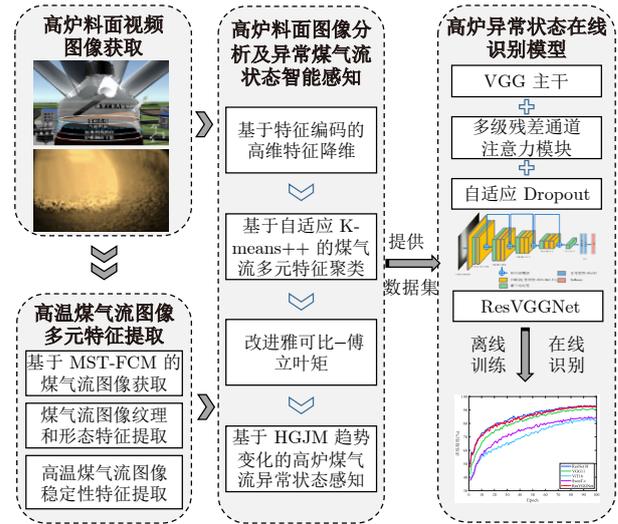


图 4 基于料面视频图像分析的高炉异常状态智能感知与识别框图

Fig. 4 Block diagram of intelligent BF anomalies perception and recognition via burden surface video image analysis

率和准确性.

假设 MFGIs 序列向量集为 $V(n) = \{\nu(1), \nu(2), \dots, \nu(n)\}$, 其中 n 为选取的 MFGIs 数量; 向量 $\nu(n)$ 是一个 D 维向量, D 为高温煤气流图像的数量. 则构造的协方差矩阵为

$$C_F = \frac{1}{n} \sum_{i=1}^n \nu(i) \nu^T(i) \quad (35)$$

利用特征编码方法, 计算得到矩阵 C_F 的特征向量 x 和特征 λ , 满足

$$\lambda x = C_F x \quad (36)$$

令

$$u = \lambda x \quad (37)$$

将式 (35) 和式 (36) 代入式 (37), 可得

$$u(n) = \frac{1}{n} \sum_{i=1}^n \nu(i) \nu^T(i) x(i) \quad (38)$$

其中, $u(n)$ 是对 u 第 n 步估计, 并且可据此得到特征向量 $x = u/\|u\|$ 和特征值 $\lambda = \|u\|$.

而 $x(i) \approx x(i-1)$, 所以, 式 (38) 可写作以下增量式表达

$$u(n) = \frac{1}{n} \sum_{i=1}^n \nu(i) \nu^T(i) \frac{u(i-1)}{\|u(i-1)\|} \quad (39)$$

令 $u(0) = \nu(1)$, 则根据数学归纳法, 式 (39) 可写作以下迭代形式

$$u(n) = \frac{n-1}{n}u(n-1) + \frac{1}{n}\nu(n)\nu^T(n) \frac{u(n-1)}{\|u(n-1)\|} \quad (40)$$

为了迭代的收敛速度, 在式 (40) 中引入小权重 ϖ , 可得

$$u(n) = \frac{n-1-\varpi}{n}u(n-1) + \frac{1+\varpi}{n}\nu(n)\nu^T(n) \frac{u(n-1)}{\|u(n-1)\|} \quad (41)$$

通过式 (41) 可计算第一主特征向量, 当计算其他高阶主特征向量时, 应从数据中减去其在估计的低一阶特征向量上的投影

$$\nu_{j+1}(n) = \nu_j(n) - \nu_j^T(n) \frac{u_j(n)}{\|u_j(n)\|} \frac{u_j(n)}{\|u_j(n)\|} \quad (42)$$

其中, $\nu_{j+1}(n)$ 为第 n 个图像特征的第 $j+1$ 阶特征向量的输入, 并且 $\nu_1(n) = \nu(n)$, 因此式 (40) 可写作

$$u_j(n) = \frac{n-1-\varpi}{n}u_j(n-1) + \frac{1+\varpi}{n}\nu_j(n)\nu_j^T(n) \frac{u_j(n-1)}{\|u_j(n-1)\|} \quad (43)$$

通过式 (43) 可迭代计算前 m 阶最大特征主成分, 得到映射矩阵

$$Q_m = \begin{bmatrix} u_1(1) & u_1(2) & \cdots & u_1(i) & \cdots & u_1(n) \\ u_2(1) & u_2(2) & \cdots & u_2(i) & \cdots & u_2(n) \\ \vdots & \vdots & \ddots & \vdots & \ddots & \vdots \\ u_j(1) & u_j(2) & \cdots & u_j(i) & \cdots & u_j(n) \\ \vdots & \vdots & \ddots & \vdots & \ddots & \vdots \\ u_m(1) & u_m(2) & \cdots & u_m(i) & \cdots & u_m(n) \end{bmatrix} \quad (44)$$

最终特征降维后的矩阵可表示为

$$V'(n) = V(n)Q_m^T \quad (45)$$

2.1.2 基于自适应 K-means++ 的煤气流图像工况聚类法

为得到粗粒度煤气流异常状态, 可对降维后的 MFGIs 进行聚类, 通过聚类结果反映粗粒度异常状态. 在给定聚类数目后, K-means++ 算法能快速、有效获得优秀的聚类效果. 但在对 MFGIs 进行工况聚类时, 聚类数目不确定. 针对该问题, 本文提出自适应 K-means++ 算法.

令降维后的 MFGIs (Dimensionality reduced MFGIs, DRM) $V'(n) = \{v_1, v_2, \dots, v_n\}$, $v_n \in \mathbf{R}^m$, 通过 K-means++ 聚类算法对 DRM 进行聚类, 得到初始聚类簇

$$C = \{C_q, q = 1, 2, 3, \dots, k\} \quad (46)$$

其中, 每一个簇 C_q 中数据的数量为 n_q , k 为聚类数. 为评价聚类的效果, 首先计算每一个簇的簇内总距离

$$\omega(k) = \sum_{q=1}^k \frac{1}{n_q} D_q \quad (47)$$

其中, D_q 为一个簇中任意两个元素间的距离之和

$$D_q = \sum_{i, j \in C_q} d(v'_i, v'_j) \quad (48)$$

具体的自适应 K-means++ 算法步骤如下:

步骤 1. 在 DRM $V'(n) = \{v_1, v_2, \dots, v_n\}$ 中随机重采样 n 次, 得到重采样 (Bootstrapping) 样本 $V^* = \{v_1^*, v_2^*, \dots, v_n^*\}$;

步骤 2. 重复步骤 1 共 N 次 (本文取 $N = 100$), 同时根据式 (47) 计算每一个 Bootstrapping 样本簇内距离总和;

步骤 3. 计算 N 次采样的 Bootstrapping 样本统计量, 并将其按照从小到大的顺序排列;

步骤 4. 由于这 N 个 Bootstrapping 统计量服从正态分布, 因此可计算得到在置信度 $1 - \alpha$ 下的置信区间

$$\left[\hat{\omega}_{\frac{\alpha}{2}}^*(k), \hat{\omega}_{1-\frac{\alpha}{2}}^*(k) \right] \quad (49)$$

根据式 (49) 可计算得到在置信区间里所有簇内距离总和 $\hat{\omega}_i^*(k)$.

根据以上 Bootstrapping 采样方法, 设计自适应聚类初值获取方法, 具体步骤如下:

步骤 1. 提出假设 H_0 和假设 H_1 , 分别为:

假设 H_0 : 原样本的最优聚类初值为 k ;

假设 H_1 : 原样本的最优聚类初值为 $k+1$;

步骤 2. 由于 k 大于 1, 因此初始化 $k = 2$;

步骤 3. 利用 K-means++ 聚类算法对原样本进行聚类, 得到 k 个簇, 并计算此时簇内距离总和 $\omega(k)$;

步骤 4. 在给定置信度 α 下, 如果 k 个聚类下的簇内距离总和 $\omega(k)$ 在置信区间所对应的 $\hat{\omega}_i^*(k)$ 里, 则接受假设 H_0 , 并输出此时的聚类初值 k ; 否则, 拒绝假设 H_0 , 接受假设 H_1 , 同时令聚类初值 $k = k+1$, 并重复步骤 3 和步骤 4.

2.2 基于改进 JFM 的细粒度煤气流异常状态感知

为精细化感知高炉煤气流异常状态, 首先直接提取煤气流图像的深层特征. 由于传统的几何图像矩不具有正交性, 因此利用几何矩进行图像特征提

取时, 会产生冗余信息, 易受外部噪声的影响, 并且仅能提取表层特征. 连续正交图像矩 JFM 具有很强的可识别能力且对噪声的鲁棒性较强, 因此本文通过改进 JFM, 实现对高温煤气流图像深层特征的稳定提取, 并基于此, 利用 t 统计量对高炉异常煤气流状态进行精细化感知.

2.2.1 改进 JFM

传统的 JFM 定义在极坐标下^[35], 但由于 CCD 的限制, 大部分图像都定义在笛卡尔坐标系下. 在计算高温煤气流图像的 JFM 时, 需要将图像转换到极坐标下, 进而会带来部分图像信息的丢失. 因此, 本文通过建立笛卡尔坐标系下的 JFM, 以适用于笛卡尔坐标系下的图像, 最大程度保留高温煤气流图像信息.

一张灰度图像由在点 (x, y) 处的亮度值 f 构成, 因此可看成一个二维密度分布 $f(x, y)$. 具体而言, 一张图像 $f(x, y)$ 的 $n+m$ 阶 JFM 定义为

$$\rho_{nm} = \frac{1}{2\pi} \int_0^1 \int_0^{2\pi} Z_{nm}^*(p, q, r, \theta) f(r, \theta) r dr d\theta \quad (50)$$

其中, $Z_{nm}^*(p, q, r, \theta) = J_n(p, q, r) e^{-jm\theta}$ 是雅可比-傅立叶基函数的复共轭, $f(r, \theta)$ 表示定义在极坐标下的图像, $p, q \in \mathbf{R}$ 且 $p - q > -1, q > 0$, 本文取 $p = 4, q = 3, r$ 为极坐标下图像的半径, θ 为半径 r 与 x 正半轴的夹角, 如图 5 所示. $J_n(p, q, r)$ 是 JFM 的径向基函数, 由式 (51) 定义

$$J_n(p, q, r) = \left(\frac{c_n(p, q, r)}{b_n(p, q)} \right)^{\frac{1}{2}} G_n(p, q) \times r^s \quad (51)$$

其中

$$c_n(p, q, r) = (1 - r)^{p-q} r^{q-2} \quad (52)$$

$$b_n(p, q) = \frac{\Gamma(q+n)n!}{\Gamma(p+n)\Gamma(p-q+n+1)(p+2n)} \quad (53)$$

$$G_n(p, q) = \sum_{s=0}^n \frac{(-1)^s \Gamma(p+n+s)}{s!(n-s)!\Gamma(q+s)} \quad (54)$$

其中, $\Gamma(\cdot)$ 是伽马函数, 其定义为

$$\Gamma(x) = \int_0^{+\infty} t^{x-1} e^{-t} dt, x > 0 \quad (55)$$

根据极坐标下 JFM 的定义, 对图像计算 JFM 时, 其积分区域如图 5 中单位圆 $R1$ 所示, $R2$ 为笛卡尔坐标系下的高温煤气流图像. 由于 $J_n(p, q, r)$ 的阶数 n 与圆周谐波阶数 m 无关, 因此 $Z_{nm}^*(p, q, r, \theta)$ 可用 $(x+iy)$ 和 $(x-iy)$ 的形式表示, 即

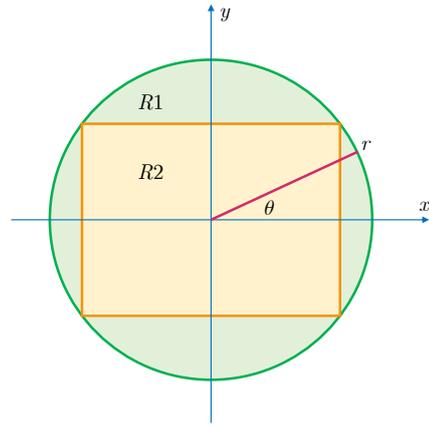


图 5 雅可比-傅立叶矩积分区域

Fig. 5 The integral region of Jacobi-Fourier moment

$$r^s e^{-jm\theta} = (x+iy)^{\frac{s-m}{2}} (x-iy)^{\frac{s+m}{2}} \quad (56)$$

将式 (56)、 $r = \sqrt{x^2 + y^2}$ 及 $p = 4, q = 3$ 代入 Z_{nm}^* 可得

$$\begin{aligned} J_n(r) e^{-jm\theta} &= \sqrt{c_n(r)} \times \sqrt{\frac{1}{b_n}} \times G_n \times r^s e^{-jm\theta} = \\ &G_n \sqrt{\frac{1}{b_n}} \sqrt{(x^2 + y^2)^{\frac{1}{2}} - (x^2 + y^2)} \times \\ &(x+iy)^{\frac{s-m}{2}} (x-iy)^{\frac{s+m}{2}} \end{aligned} \quad (57)$$

所以, 笛卡尔坐标系下的 JFM 为

$$\begin{aligned} \rho_{nm} &= \frac{1}{2\pi} \int_0^1 \int_0^{2\pi} Z_{nm}^*(p, q, r, \theta) f(r, \theta) r dr d\theta = \\ &\frac{1}{2\pi} \iint_{R1} f(r, \theta) Z_{nm}^*(r, \theta) ds \end{aligned} \quad (58)$$

区域 $R1$ 包括 $R2$ 区域, 因此, 式 (58) 可写为

$$\begin{aligned} \rho_{nm} &= \frac{1}{2\pi} \iint_{R2} f(r, \theta) Z_{nm}^*(r, \theta) ds + \\ &\frac{1}{2\pi} \iint_{R1-R2} f(r, \theta) Z_{nm}^*(r, \theta) ds \end{aligned} \quad (59)$$

由于 $R1 - R2$ 不是图像的一部分, 并且其中没有像素, 因此, 式 (59) 可写为

$$\rho_{nm} = \frac{1}{2\pi} \iint_{R2} f(x, y) J_n \times \sqrt{x^2 + y^2} e^{-jm(\arctan(\frac{y}{x}) + k\pi)} dx dy \quad (60)$$

通过式 (60) 可得到高温煤气流图像 JFM (JFM of high-temperature gas flow image, HGJM).

2.2.2 基于 HGJM 趋势变化的高炉煤气流异常状态精细化感知

高炉料面中心高温煤气流随状态不断变化, 因

此, 根据料面图像获取的 HGJM 也会随时间不断变化. 高炉运行状态在稳定时不会突变, 而当煤气流异常状态发生时, 可认为高炉状态的趋势发生了变化, 可直接利用 HGJM 进行描述. 高炉运行状态的变化具有非线性、非平稳、多层次等特征, 难以直接得到其趋势变化情况. 为准确获取高炉运行状态情况, 本文利用 HGJM 对高炉异常状态进行精细化感知, 具体如下.

对于包含 N 个 HGJM 序列数据的 X , 通过第 n ($1 < n < N$) 个数据将 X 分为 X_{left} 和 X_{right} 左右两个子序列数据, 分别包含 N_{left} 和 N_{right} ($N_{\text{right}} = N - N_{\text{left}}$) 个数据. 分别计算子序列数据的均值 u_{left} 和 u_{right} 、标准差 σ_{left} 和 σ_{right} , 并计算 t 统计量, 由式 (61) 定义

$$t(n) = \left| \frac{u_{\text{left}} - u_{\text{right}}}{\sigma_D(n)} \right| \quad (61)$$

其中, $\sigma_D(n)$ 是合并方差, 由下式定义

$$\sigma_D(n) = \left(\frac{\sigma_{\text{left}}^2 + \sigma_{\text{right}}^2}{N_{\text{left}} + N_{\text{right}} - 2} \right)^{\frac{1}{2}} \left(\frac{1}{N_{\text{left}}} + \frac{1}{N_{\text{right}}} \right)^{\frac{1}{2}} \quad (62)$$

根据式 (62), 依次计算每个数据的 t 统计量, 得到关于 t 统计量的序列, 获得其中的最大值 t_{max} 及此时的 n . 计算此时的显著性特征 $E(t_{\text{max}})$

$$E(t_{\text{max}}) = \text{Prob}(t \leq t_{\text{max}}) \quad (63)$$

其中, $\text{Prob}(\cdot)$ 为概率密度计算函数.

因此, $E(t_{\text{max}})$ 可近似由式 (64) 表示

$$E(t_{\text{max}}) \approx \left(1 - I_{\frac{v}{v+t_{\text{max}}^2}}(\beta v, \beta) \right)^\alpha \quad (64)$$

其中, $\alpha = 4.19 \ln N - 11.54$, $\beta = 0.40$, $v = N - 2$, $I_a(b, c)$ 是不完全 beta 函数, 由下式定义

$$I_a(b, c) = \int_0^a x^{b-1} (1-x)^{c-1} dx \quad (65)$$

其中, $0 < a < 1$; $b, c > 0$.

具体的步骤如下:

步骤 1. 输入 HGJM 数据, 初始化 n ;

步骤 2. 根据式 (61) 计算 HGJM 每一个数据的 t 统计量, 得到其中的最大值 t_{max} 及此时的 n ;

步骤 3. 根据式 (64) 计算 t_{max} 的统计显著性特征 $E(t_{\text{max}})$, 若 $E(t_{\text{max}})$ 超过选定的显著性水平 E_0 (本文取 0.95), 则在该处将原序列分割为两个子序列, 并且对两个子序列重复进行步骤 2 和步骤 3, 直到序列不可分割为止; 否则结束分割.

此分割点即煤气流异常状态发生处, 由于异常状态的发生是量变引起质变, 因此本文认为在异常

处前后共一分钟的高炉料面图像均属于煤气流异常状态对应的图像.

2.3 基于 ResVGGNet 的高炉异常状态在线识别模型

基于以上研究, 可构建高炉正常状态和不同异常状态图像数据集, 从而将高炉异常状态识别问题转化为高炉料面图像分类问题. 深度学习可通过端到端的训练提取深层特征, 进而可完成图像分类任务. 目前, 基于 Transformer 的模型以及卷积神经网络比较流行且效果较好. 然而基于注意力机制的 Transformer 模型需将图像分割成多个块后输入网络, 导致模型训练及推理时间大大增加, 不利于高炉异常状态的在线识别.

在各种深度网络中, 卷积神经网络在图像分类等任务中得到了最广泛的研究与应用. VGG 作为深度卷积网络, 由于其优秀的特征表示和学习能力, 可获得比其他算法更好的分类精度. 原始 VGG11 网络^[36] 包含 5 个 VGG 卷积模块, 每个模块包含 1~2 个卷积层和最大池化层, 一共由 8 个卷积层和 3 个全连接层组成. VGG 网络训练直接学习输入与输出之间的映射关系, 但网络在训练过程中, 大量的卷积层和全连接层在增加网络训练复杂性的同时, 还存在特征信息和通道信息损失的情况. 特征信息损失会使得网络训练和推理速度减慢, 通道信息损失会使得网络的精度难以进一步提升. 为解决该问题, 本文提出 MRCAM, 融合 VGG 块结构, 构建 ResVGGNet, 实现高精度实时高炉异常状态在线识别.

2.3.1 ResVGGNet 模型整体结构

ResVGGNet 模型结构如图 6 所示, 具体的网络模型结构为:

1) ResVGGNet 主要包括 VGG 块和 MR-CAM, VGG 块使用卷积核、步长为 1 的卷积层和卷积核、步长为 2 的最大池化层, 同时在之后设置有批归一化 (Batch normalization, BN). MRCAM 包括多个残差通道注意力模块 (Residual channel attention module, RCAM), RCAM 由残差结构和通道注意力模块组成. 残差结构中的恒等映射使用 1×1 的卷积核, 用于匹配图像通道的数量, 同时将上一层的输出特征直接输入到下一层中.

2) 第一层是网络的输入层, 网络的输入为 $224 \times 224 \times 3$ 的料面图像, 经过 1 个 VGG 块和最大池化层, 用于丰富特征图, 即纹理特征. 其中的 ReLU 函数可以改变模型的线性结构, 增强模型的非线性, 从而减少模型的过拟合. 而第二层仅包含 1 个 VGG 块, 用于进一步丰富特征图.

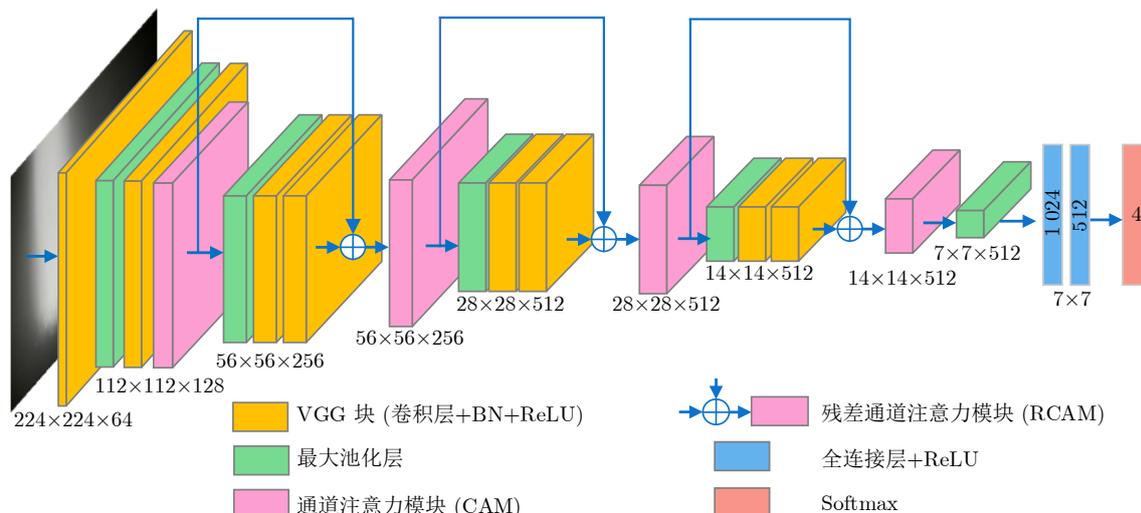


图6 ResVGGNet 模型结构

Fig.6 The structure of ResVGGNet model

3) 第三、四、五层均具有两个 VGG 块, 并且在这些层前后设置有 RCAM, 用于提取料面图像的多尺度特征并关注特征的通道信息差异. 料面区域与高温煤气流区域存在一定的边界, 而高温煤气流区域对分类具有重要作用, 因此需要获取料面局部特征, 加入 RCAM 能有效提取该特征, 并且能减少不同 VGG 块之间的特征损失, 加速梯度跨层传播能力, 因而能加快模型识别速度. 同时, RCAM 中的通道注意力模块 (Channel attention module, CAM) 能有效提升模型对通道信息差异的关注, 进而提升模型的精度.

4) 最后, 使用两个全连接层 F_1 和 F_2 减少模型参数数量, 参数分别设置为 1024 和 512, 并使用 Softmax 函数作为分类器, 神经元的个数设置为 4, 代表正常、塌料、悬料和煤气流异常状态四种状态.

2.3.2 多级残差通道注意力模块

传统的残差结构如图 7 所示, 残差结构在输入与后续的输出之间加入跳跃连接^[37], 在很大程度上避免了信息的损失, 同时也降低了学习的难度. 这样能在不增加网络额外参数和计算量的前提下, 很好解决网络在训练过程中的退化问题, 加速模型训练, 同时提升模型的训练效果.

基于卷积神经网络的特征提取模块中有许多卷积层和池化层, 采用残差结构能在一定程度上减少特征信息的丢失, 但通道信息丢失依然存在. 传统的卷积网络利用卷积与池化层增加特征图的通道数, 提取了语义特征和浅层特征的复合特征, 但对所有的通道都是进行相同的处理, 没有充分考虑通道之间的差异性信息, 这是不合理的. 为解决该问

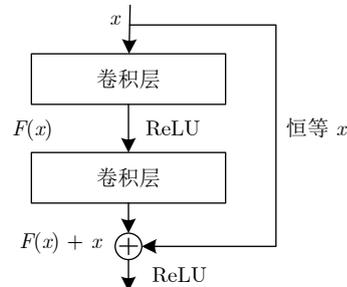


图7 残差结构

Fig.7 The residual structure

题, 针对残差结构提取的特征, 本节提出通道注意力模块, 如图 8 所示, 使模型能关注通道信息之间的差异.

给定输入特征图, 首先可通过 CAM 计算通道注意力

$$w = \varphi(Wy) \quad (66)$$

其中, φ 为 Sigmoid 函数, W 是 $N \times N$ 的参数矩阵, 具体为

$$W = \begin{bmatrix} w_{1,1} & \cdots & w_{1,n} & 0 & 0 & \cdots & \cdots & 0 \\ 0 & w_{2,2} & \cdots & w_{2,n+1} & 0 & \cdots & \cdots & 0 \\ \vdots & \vdots & \vdots & \vdots & \ddots & \vdots & \vdots & \vdots \\ 0 & \cdots & 0 & 0 & \cdots & w_{N,N-n+1} & \cdots & w_{N,N} \end{bmatrix} \quad (67)$$

为提高 CAM 的性能, 让所有的通道共享权重信息

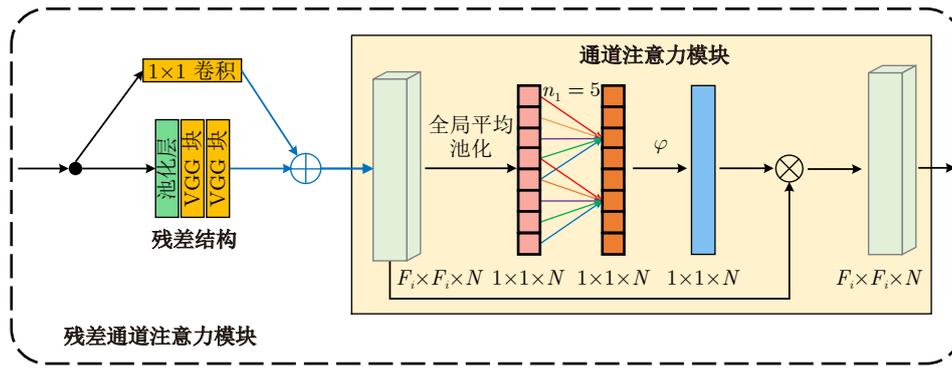


图 8 RCAM 结构

Fig.8 The structure of RCAM

$$w^i = \varphi \left(\sum_{j=1}^n w_j y_j^i \right), y_j^i \in \vartheta_n^i \quad (68)$$

其中, ϑ_n^i 表示 y^i 的 n 个相邻通道的集合.

根据以上分析, 可以通过设计卷积核大小为 n_1 的一维卷积来实现式 (68) 表示的通道之间的信息交互

$$w = \varphi (ConV_{n_1}^{1D} (y)) \quad (69)$$

其中, $ConV^{1D}$ 表示一维卷积.

分组卷积^[38]已经成功用于改善 CNN 的结构, 其通过在给定固定数目的分组卷积下, 使高维或者低维通道包含长程卷积或者短程卷积. 因此, 类似地, 可认为跨通道信息交互作用的范围 (即一维卷积的卷积核大小 n_1) 与通道维数 N 成正比, 即 n_1 和 N 之间可能存在函数关系

$$N = f(n_1) \quad (70)$$

由于通道维度一般都是 2 的指数次幂, 因此, 采用以 2 为底的指数函数表示这种函数关系

$$N = 2^{(\alpha_1 n_1 + \beta_1)} \quad (71)$$

其中, α_1 和 β_1 是超参数, 本文 α_1 和 β_1 分别设置为 2 和 1.

因此, 根据式 (71), 在给定通道维数 N 的情况下, 可以得到卷积核的大小为

$$n_1 = f^{-1}(N) = \left\lfloor \frac{\log_2 N}{\alpha_1} + \frac{\beta_1}{\alpha_1} \right\rfloor_{\text{odd}} \quad (72)$$

其中 $\lfloor \cdot \rfloor_{\text{odd}}$ 表示距离结果最近的奇数.

在全连接层与 Softmax 分类器之间, 通常采用 Dropout 操作, 避免网络过度依赖某个神经元, 减少过拟合, 使得训练结果更准确. 传统的 Dropout 操作具有固定的失活概率, 但实际上, 不同节点之间的重要性可能不同. 基于此, 本文提出自适应 Dro-

out, 通过引入以下自适应函数来设置每层的激活率 χ , 以改善 Dropout 的性能

$$\chi = \begin{cases} 1 - \frac{1}{\sigma\sqrt{2\pi}} \int_{-\infty}^l e^{-\frac{(l-\frac{n}{2})^2}{2\sigma^2}} dl, & n = 2k \\ 1 - \frac{1}{\sigma\sqrt{2\pi}} \int_{-\infty}^l e^{-\frac{(l-\frac{n+1}{2})^2}{2\sigma^2}} dl, & n = 2k + 1 \end{cases} \quad (73)$$

其中, n 和 l 分别为网络层数和网络层的位置, k 为正整数 ($k \in \mathbf{N}_+$).

对于图像分类网络而言, 损失函数与优化算法对于网络收敛十分关键. 交叉熵损失是深度学习分类问题中一种常用的损失函数, 其可衡量模型预测结果与实际标签之间的差距. 由于本文是多分类问题, 交叉熵损失函数由式 (74) 定义

$$Loss = -\frac{1}{K} \sum_{i=0}^{K-1} \sum_{c=0}^3 L_{ic} \log_2 P_{ic} \quad (74)$$

其中, K 表示样本总数, c 表示类别, L_{ic} 表示第 i 个样本类别为 c 的标签 (0 表示塌料, 1 表示煤气流状态异常, 2 表示悬料, 3 表示正常), P_{ic} 为输入第 i 个样本预测为 c 类的概率.

为更好地训练, 本文使用自适应矩估计 (Adaptive moment estimation, Adam) 优化算法, 其通过结合动量随机梯度下降和偏差校正等优势, 不仅使用动量作为参数更新方向, 而且可以自适应调整学习率, 从而加速训练过程. 具体优化过程如下:

首先, 分别计算一阶与二阶动量累积值 ν_t 和 ϖ_t

$$\nu_t = \beta_2 \nu_{t-1} + (1 - \beta_2) g_t \quad (75)$$

$$\varpi_t = \beta_3 \varpi_{t-1} + (1 - \beta_3) g_t^2 \quad (76)$$

其中, g_t 为模型当前计算的梯度.

然后, 对偏差进行修正

$$\hat{\nu}_t = \frac{\nu_t}{1 - \beta_2^t} \quad (77)$$

$$\hat{\omega}_t = \frac{\omega_t}{1 - \beta_3^t} \quad (78)$$

最后计算参数更新差值, 进行参数更新

$$\delta_{t+1} = \delta_t - \frac{\alpha_2}{\sqrt{\hat{\omega}_t + \varepsilon}} \hat{\nu}_t \quad (79)$$

其中, 超参数 $\beta_2 = 0.9$, $\beta_3 = 0.999$, $\alpha_2 = 0.001$, $\varepsilon = 10^{-8}$.

3 实例验证

为验证所提方法的有效性, 本文采用安装于华南地区某钢铁集团 2# 高炉上的新型工业内窥镜获取的高炉料面视频图像进行实验. 本文的实验分为两部分: 首先利用所提的煤气流异常状态智能感知方法对高炉料面图像进行处理, 精细化感知煤气流

异常状态, 同时通过高炉专家对塌料、悬料视频图像进行分类, 构成高炉异常状态识别图像数据集; 然后基于该数据集对建立的 ResVGGNet 进行训练, 进而实现高炉状态识别, 并与最先进的图像分类方法和高炉异常状态识别方法进行对比.

3.1 高炉煤气流异常状态感知结果

本文选取正常状态和异常状态下 13 分钟高炉料面视频图像, 利用所提方法提取各自降维后的高温煤气流图像多元特征, 如图 9 所示. 由图 9 可知, 降维后的特征之间的距离比较明显, 特别地, 对于图 9(b), 能清楚地看到数据成簇分布, 这直接说明了所提多元特征提取及降维方法的有效性.

然后, 对其进行自适应 K-means++ 聚类, 结果如图 10 所示. 其中, 正常状态下的聚类数为 4, 发生了异常状态的聚类数为 5. 分析每个聚类下高温煤气流图像对应的原始高炉料面图像, 在正常状

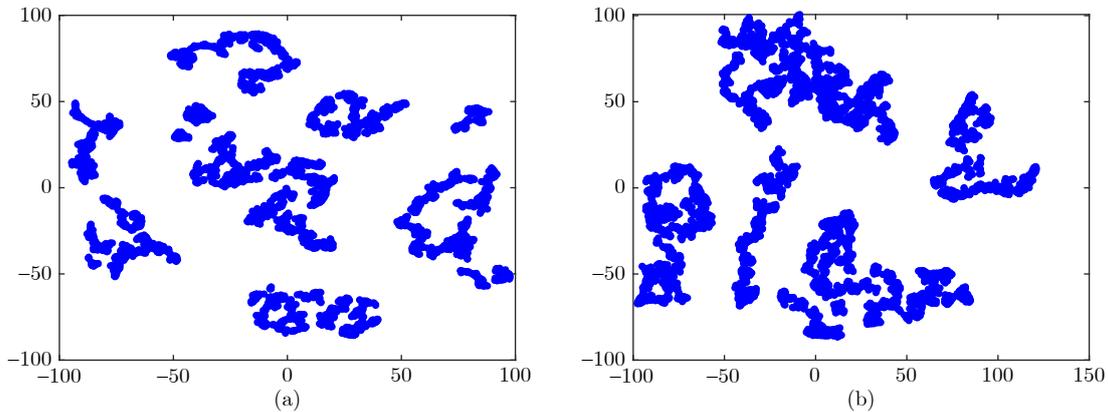


图 9 不同状态下高温煤气流图像多元特征降维结果 ((a) 正常状态; (b) 异常状态)

Fig.9 The multi-feature results of high-temperature gas flow images from different BF statuses after dimensionality reduction ((a) Normal status; (b) Abnormal status)

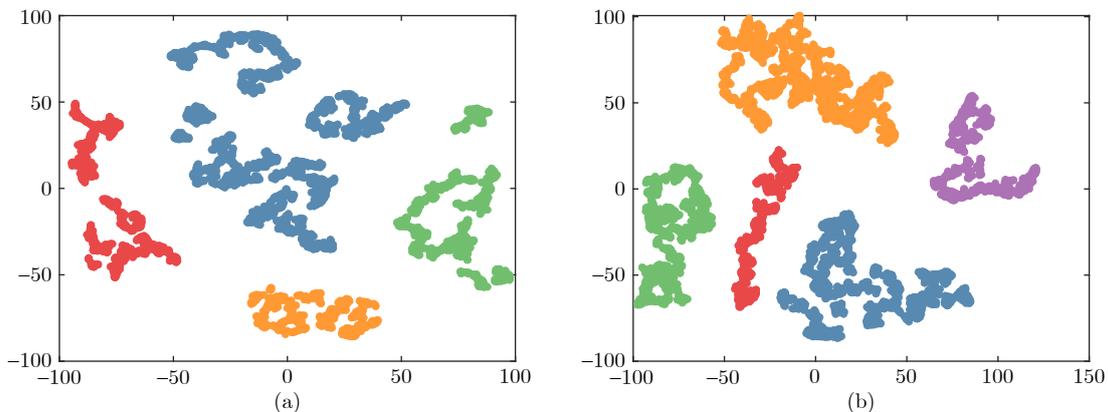


图 10 不同状态下高温煤气流图像多元特征聚类结果 ((a) 正常状态; (b) 异常状态)

Fig.10 The multi-feature results of high-temperature gas flow images from different BF statuses after clustering ((a) Normal status; (b) Abnormal status)

态下,分为布料、加焦、煤气流状态稳定和煤气流状态较为稳定四种情况;而当煤气流异常状态发生时,则增加一个聚类,这与高炉冶炼实际情况相符.因此,基于此可得到粗粒度煤气流异常状态,从而判断一段时间内是否发生煤气流异常状态.

据此,对其他高温煤气流图像进行处理,得到各时间段异常高炉煤气流图像.首先提取每帧煤气流图像的HGJM,并基于HGJM趋势变化对煤气流异常状态进行精细化感知,得到细粒度煤气流异常状态.如图11所示,选取20000张连续的煤气流图像进行处理,红色虚线处即为煤气流异常状态发生处.

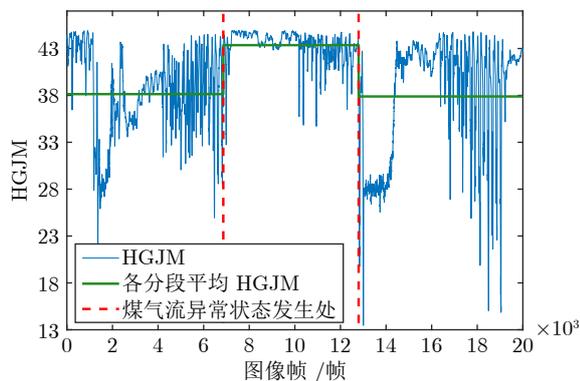


图 11 基于 HGJM 趋势变化的煤气流异常状态感知结果

Fig. 11 The perception results of gas flow anomaly based on HGJM trend change

3.2 高炉异常状态识别结果

本文实验共有 2400 张煤气流异常状态图像,同时为保证样本数目符合真实情况,高炉料面图像数据集中共有塌料图像 800 张,悬料图像 1200 张,正常状态图像 2400 张.训练集与测试集按照 4:1 的比例划分,具体的高炉料面图像数据集如表 1 所示.

表 1 高炉料面图像数据集
Table 1 Dataset of BF burden surface images

高炉状态	塌料	煤气流异常	悬料	正常
训练集	640	1920	960	1920
测试集	160	480	240	480

本文实验使用 Adam 优化器,动量系数为 0.9,模型最大学习率为 0.001,100 个 epoch,每隔 10 个 epoch 学习率衰减 10%,同时选用交叉熵损失函数训练和优化 ResVGGNet.根据所提自适应 Dropout 函数,全连接层和与 Softmax 分类层之间的隐藏层的激活率设置为 80% 和 60%.实验在 Win10

系统下,软件环境为 PythonTM3.8.15 和 Torch1.2.0,硬件环境为 Intel(R) Xeon(R) Gold 256 GB, NVIDIA® Telsa V100S.

为验证所提 ResVGGNet 的有效性,本文选取主流的卷积网络 ResNet18^[37]、VGG11^[36] 以及目前流行的 Transformer 模型 ViT16^[39] 和 SwinT-t^[40].为保证实验的公平性与准确性,所有网络均采用相同的高炉状态料面图像数据集,并且网络的所有超参数均一致.

图 12 展示了上述网络在训练和测试阶段的精度与损失情况.从图 12 可知,相比 VGG11、ViT16 和 SwinT-t,本文所提 ResVGGNet 的训练和测试精度都是最高的.虽然 ResNet18 的训练精度和训练损失与所提 ResVGGNet 相差较小,但是在测试阶段,ResNet18 波动过大,不利于模型的快速收敛.

为进一步定量比较以上方法的效果,使用异常状态检测率 (Fault detection rate, FDR) 和正常状态误报率 (False alarm rate, FAR) 作为定量指标,同时定义描述模型的识别速度,分别为

$$FDR = \frac{\text{识别对的样本数}}{\text{异常状态某类别样本总数}} \quad (80)$$

$$FAR = \frac{\text{识别为故障的样本数}}{\text{正常状态样本总数}} \quad (81)$$

$$v_{\text{识别}} = \frac{\text{测试集样本数}}{\text{识别所用时间}} \quad (82)$$

根据式 (80)、式 (81) 和式 (82) 分别计算以上方法的检测率、误报率和识别速度,结果如表 2 所示.由于新型工业内窥镜获取的料面视频图像是 25 帧/s,因此模型对图像的分类速度至少要大于 25 帧/s 才能做到实时处理,考虑到实际现场数据传输需要时间,因此,识别速度越快越好.由表 2 可知,ResNet18 由于在训练中能够充分利用网络残差信息,整体性能比 VGG11、ViT16 和 SwinT-t 均要高.单纯只使用具有残差结构的 ResNet18 和只具有 VGG 块的 VGG11,整体性能均劣于所提方法. ResVGGNet 的识别速度最快,同时不同异常状态的检测率均较高,而在正常状态下的误报率保持最低,验证了本文所提方法的有效性.

最后,也与现有的高炉异常状态识别方法进行对比.由于现有方法中针对塌料的诊断较为缺乏,而针对悬料状态的诊断方法相对较多,因此,本文选取能对悬料状态进行监测的相关方法,包括基于多元统计分析的方法 CA^[11]、MWPCA^[41]、SFIC-VA^[12]、Local-DBKSSA (L-DBKSSA)^[20]、Adaptive DiASSA (A-DiASSA)^[21] 和基于深度学习的方法

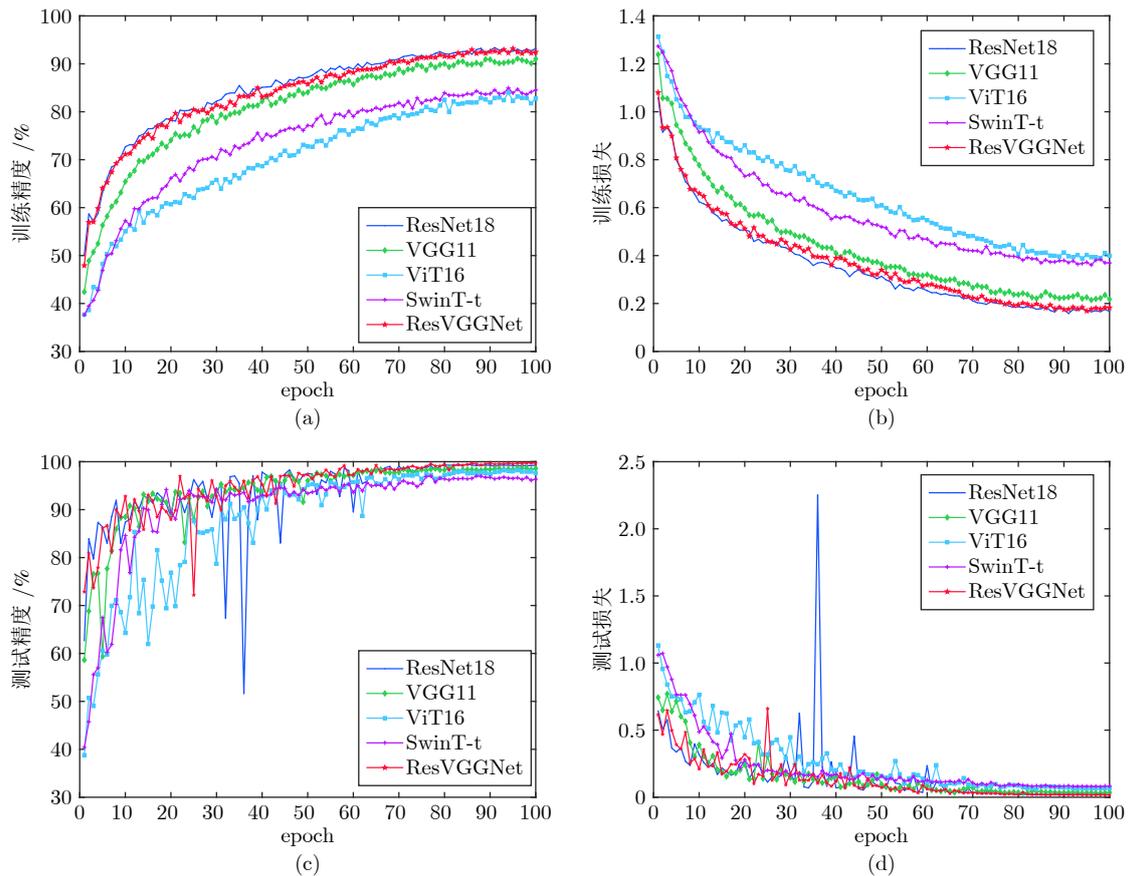


图 12 不同分类网络模型训练与测试结果 ((a) 训练精度; (b) 训练损失; (c) 测试精度; (d) 测试损失)
 Fig. 12 Training and test results of different classification network models ((a) Training accuracy;
 (b) Training loss; (c) Test accuracy; (d) Test loss)

表 2 不同分类网络在高炉料面图像数据集下的识别结果

Table 2 Recognition results of different classification networks under BF burden surface image dataset

网络名称	异常状态检测率 \uparrow			误报率 \downarrow	速度 (帧/s) \uparrow
	塌料	煤气流异常	悬料	正常状态	
ResNet18	100.00%	98.54%	99.58%	0.42%	42.94
VGG11	100.00%	98.33%	99.58%	2.29%	35.29
ViT16	100.00%	99.38%	<u>98.75%</u>	1.67%	23.32
SwinT-t	100.00%	<u>93.96%</u>	99.58%	<u>3.96%</u>	<u>8.98</u>
ResVGGNet	100.00%	99.30%	99.58%	0.21%	60.26

注: \uparrow 表示指标越大越好, \downarrow 表示指标越小越好, 粗体表示指标最优, 下划线表示指标最差。

DSKL-SVM^[18]、SD-DAE^[4]。具体的对比结果如表 3 所示。从表 3 可看出, 本文方法对悬料的检测率为第二优, 而悬料检测率高于本文方法的 Local-DB-KSSA 和 DSKL-SVM, 其在正常状态下的误报率分别为 1.24% 和 17.00%。误报率越大, 在正常高炉运行状态下误报的概率越高, 这会给现场带来额外的不必要的工作。本文所提方法在维持对悬料的诊断率 99.58% 的情况下, 在正常状态下的误报率仅为 0.21%, 验证了本文方法的优异性能。

4 结束语

本文提出一种全新的基于高炉料面视频图像分析的煤气流异常状态感知与不同高炉异常状态实时识别方法。通过对高炉料面视频图像的分析, 发现了煤气流异常状态这一特殊的高炉异常状态。通过将高炉料面图像不同尺度的纹理信息与 FCM 结合, 提出基于 MST-FCM 的高温煤气流区域获取方法, 可以在无标注样本的情况下, 准确提取煤气流

表 3 不同高炉异常状态识别方法对比
Table 3 Comparison among different BF anomaly recognition methods

类型	方法名称	悬料状态	正常状态
		检测率↑	误报率↓
多元统计分析	CA	71.20%	4.60%
	MWPCA	96.45%	3.76%
	SFICVA	89.50%	3.00%
	L-DBKSSA	100.00%	<i>1.24%</i>
	A-DiASSA	92.80%	1.40%
深度学习	DSKL-SVM	100.00%	<u>17.00%</u>
	SD-DAE	93.77%	10.40%
料面图像法	所提方法	<i>99.58%</i>	0.21%

注: ↑表示指标越大越好, ↓表示指标越小越好, 粗体表示指标最优, 斜体表示指标第二优, 下划线表示指标最差。

图像. 在提取煤气流图像多元特征后, 提出基于特征编码的特征降维方法, 同时利用 Bootstrapping 方法探索了自适应初值的 K-means++ 聚类方法, 其能自动给定聚类初值, 实现煤气流异常状态的粗粒度感知. 然后, 通过改进 JFM, 并利用 t 统计量对 HGJM 变化趋势进行分析, 精准感知煤气流异常状态. 最后, 通过设计 MRCAM, 提出高炉异常状态识别模型 ResVGGNet, 实现高炉塌料、悬料和煤气流异常三种不同异常状态的精准快速在线识别. 与现有的图像分类网络相比, 本文所提方法在保证高检测率和低误报率的同时, 识别速度最快; 而与现有的高炉异常状态识别方法相比, 所提方法也具有明显优势. 本文为基于料面图像的高炉异常状态识别提供了初步的研究, 未来的研究将包括以下两个方面:

1) 异常状态预测: 所提方法主要侧重对短期高炉异常状态的实时识别, 进而帮助高炉实时调控. 而在实际高炉现场也关心未来时刻高炉是否会出现异常状态, 进而做到提前调控. 在未来的工作中, 将继续研究把 ResVGGNet 拓展到高炉异常状态预测领域, 实现对不同高炉异常状态的提前预测.

2) 长期炉况识别与监测: 高炉向热和向凉是高炉重要的长期炉况, 但针对长期炉况的监测方法较少. 而高炉视频图像存在明显的时间序列变化特性, 具有识别长期炉况的潜力, 未来将通过对大量连续的高炉视频图像进行分析与处理, 把所提方法进一步拓展到长期炉况的识别与监测领域.

References

- Liu J S, Jiang Z H, Gui W H, Chen Z W. A novel particle size detection system based on RGB-laser fusion segmentation with feature dual-recalibration for blast furnace materials. *IEEE Transactions on Industrial Electronics*, 2023, **70**(10): 10690–10699
- Zhu J L, Gui W H, Chen Z P, Jiang Z H. A novel non-contact and real-time blast furnace stockline detection method based on burden surface video streams. *IEEE Transactions on Instrumentation and Measurement*, 2023, **72**: Article No. 4502213
- Zhou Ping, Liu Ji-Ping, Liang Meng-Yuan, Zhang Rui-Yao. KPLS robust reconstruction error-based monitoring and anomaly identification of fuel ratio in blast furnace ironmaking. *Acta Automatica Sinica*, 2021, **47**(7): 1661–1671 (周平, 刘记平, 梁梦园, 张瑞堦. 基于 KPLS 鲁棒重构误差的高炉燃料比监测与异常识别. *自动化学报*, 2021, **47**(7): 1661–1671)
- Jiang K, Jiang Z H, Xie Y F, Pan D, Gui W H. Abnormality monitoring in the blast furnace ironmaking process based on stacked dynamic target-driven denoising autoencoders. *IEEE Transactions on Industrial Informatics*, 2022, **18**(3): 1854–1863
- Takatani K, Iwanaga Y. Fundamental study on thermal degradation of coke during rapid heating. *Tetsu-to-Hagane*, 1986, **72**(2): 189–194
- Li Jun-Feng. Study on Heat Flux Intensity of Blast Furnace Body and Smooth Operation of Blast Furnace Condition [Master thesis], Kunming University of Science and Technology, China, 2014. (李骏峰. 高炉炉体热流强度与炉况顺行的研究 [硕士学位论文], 昆明理工大学, 中国, 2014.)
- Zhou P, Li H L, Shi P Y, Zhou C Q. Simulation of the transfer process in the blast furnace shaft with layered burden. *Applied Thermal Engineering*, 2016, **95**: 296–302
- Chen Jian-Hua, Xu Hong-Yang. Application status and development trend of “blast furnace expert system”. *Modern Metallurgy*, 2012, **40**(3): 6–10 (陈建华, 徐红阳. “高炉专家系统”应用现状和发展趋势. *现代冶金*, 2012, **40**(3): 6–10)
- Dong Y N, Qin S J. A novel dynamic PCA algorithm for dynamic data modeling and process monitoring. *Journal of Process Control*, 2018, **67**: 1–11
- Zhou P, Zhang R Y, Xie J, Liu J P, Wang H, Chai T Y. Data-driven monitoring and diagnosing of abnormal furnace conditions in blast furnace ironmaking: An integrated PCA-ICA method. *IEEE Transactions on Industrial Electronics*, 2021, **68**(1): 622–631
- Chen Q, Kruger U, Leung A Y T. Cointegration testing method for monitoring nonstationary processes. *Industrial and Engineering Chemistry Research*, 2009, **48**(7): 3533–3543
- Lou S W, Wu P, Yang C J, Xu Y H. Structured fault information-aided canonical variate analysis model for dynamic process monitoring. *Journal of Process Control*, 2023, **124**: 54–69
- Zhao Ming. Study on Diagnose and Forecast of Blast Furnace Condition Based on Neural Network [Master thesis], Northeastern University, China, 2010. (赵明. 基于神经网络的高炉炉况诊断与预报研究 [硕士学位论文], 东北大学, 中国, 2010.)
- Gao C H, Jian L, Luo S H. Modeling of the thermal state change of blast furnace hearth with support vector machines. *IEEE Transactions on Industrial Electronics*, 2012, **59**(2): 1134–1145
- Luo S H, Dai Z A, Chen T X, Chen H Y, Jian L. A weighted SVM ensemble predictor based on AdaBoost for blast furnace ironmaking process. *Applied Intelligence*, 2020, **50**: 1997–2008
- Li J P, Hua C C, Yang Y N, Guan X P. Bayesian block structure sparse based T-S fuzzy modeling for dynamic prediction of hot metal silicon content in the blast furnace. *IEEE Transactions on Industrial Electronics*, 2018, **65**(6): 4933–4942
- Zhao Hui, Zhao De-Tao, Yue You-Jun, Wang Hong-Jun. Research on fault classification of blast furnace condition based on

- deep belief network. *Foundry Technology*, 2018, **39**(5): 1028–1032
(赵辉, 赵德涛, 岳有军, 王红君. 基于深度置信网络的高炉炉况故障分类方法的研究. 铸造技术, 2018, **39**(5): 1028–1032)
- 18 Lou S W, Yang C J, Wu P, Kong L Y, Xu Y H. Fault diagnosis of blast furnace iron-making process with a novel deep stationary kernel learning support vector machine approach. *IEEE Transactions on Instrumentation and Measurement*, 2022, **71**: Article No. 3521913
- 19 Han Y H, Li Q, Wang C, Zhao Q. A novel knowledge enhanced graph neural networks for fault diagnosis with application to blast furnace process safety. *Process Safety and Environmental Protection*, 2022, **166**: 143–157
- 20 Lou S W, Yang C J, Wu P. A local dynamic broad kernel stationary subspace analysis for monitoring blast furnace ironmaking process. *IEEE Transactions on Industrial Informatics*, 2023, **19**(4): 5945–5955
- 21 Lou S W, Yang C J, Zhu X Z, Zhang H W, Wu P. Adaptive dynamic inferential analytic stationary subspace analysis: A novel method for fault detection in blast furnace ironmaking process. *Information Sciences*, 2023, **642**: Article No. 119176
- 22 Shi L, Wen Y B, Zhao G S, Yu T. Recognition of blast furnace gas flow center distribution based on infrared image processing. *Journal of Iron and Steel Research International*, 2016, **23**(3): 203–209
- 23 Pan D, Jiang Z H, Chen Z P, Jiang K, Gui W H. Compensation method for molten iron temperature measurement based on heterogeneous features of infrared thermal images. *IEEE Transactions on Industrial Informatics*, 2020, **16**(11): 7056–7066
- 24 He L, Jiang Z H, Xie Y F, Chen Z P, Gui W H. Velocity measurement of blast furnace molten iron based on mixed morphological features of boundary pixel sets. *IEEE Transactions on Instrumentation and Measurement*, 2021, **70**: Article No. 5018312
- 25 He L, Jiang Z H, Xie Y F, Gui W H, Chen Z P. Mass flow measurement of molten iron from blast furnace, based on trusted region stacking using single high-speed camera. *IEEE Transactions on Instrumentation and Measurement*, 2021, **70**: Article No. 5013011
- 26 Li Q, Wang Z J, Wang S, Li M M, Lei H, Zou Z S. A deep learning-based diagnosis model driven by tuyere images big data for iron-making blast furnaces. *Steel Research International*, 2022, **93**(8): Article No. 2100826
- 27 Yi Z H, Jiang Z H, Huang J C, Chen X F, Gui W H. Optimization method of the installation direction of industrial endoscopes for increasing the imaged burden surface area in blast furnaces. *IEEE Transactions on Industrial Informatics*, 2022, **18**(11): 7729–7740
- 28 Xu T X, Chen Z P, Jiang Z H, Huang J C, Gui W H. A real-time 3D measurement system for the blast furnace burden surface using high-temperature industrial endoscope. *Sensors*, 2020, **20**(3): Article No. 869
- 29 Zhao Zhi-Jian, She Xue-Feng, Zhao Yi-Zhe, Liu Yan-Jun, Wang Ai-Jun, Li Li-Long, et al. Numerical simulation study on the influence of burden profile on gas distribution in blast furnace. *Journal of Materials and Metallurgy*, 2023, **22**(1): 38–44
(赵志坚, 余雪峰, 赵奕喆, 刘燕军, 王艾军, 李丽红, 等. 高炉料面结构对煤气流分布影响的模拟. 材料与冶金学报, 2023, **22**(1): 38–44)
- 30 Guo Heng-Guang, Zhu Mo, Zhao Liang. Texture feature extraction method based on multiscale orientation decomposition. *Computing Technology and Automation*, 2021, **40**(4): 102–107
(郭恒光, 朱默, 赵亮. 基于多尺度方向分解的纹理特征提取方法研究. 计算技术与自动化, 2021, **40**(4): 102–107)
- 31 Guo W H, Xu G X, Liu B D, Wang Y J. Hyperspectral image classification using CNN-enhanced multi-level Haar wavelet features fusion network. *IEEE Geoscience and Remote Sensing Letters*, 2022, **19**: Article No. 6008805
- 32 Shi Z H, Wu D R, Guo C F, Zhao C M, Cui Y Q, Wang F Y. FCM-RDpA: TSK fuzzy regression model construction using fuzzy C-means clustering, regularization, DropRule, and Powerball AdaBelief. *Information Sciences*, 2021, **574**: 490–504
- 33 Kirillov A, Mintun E, Ravi N, Mao H Z, Rolland C, Gustafson L, et al. Segment anything. arXiv preprint arXiv: 2304.02643, 2023.
- 34 Zhu Ye, Shen Xuan-Jing, Chen Hai-Peng. Covert copy-move forgery detection based on color LBP. *Acta Automatica Sinica*, 2017, **43**(3): 390–397
(朱叶, 申铨京, 陈海鹏. 基于彩色 LBP 的隐蔽性复制-粘贴篡改鉴别算法. 自动化学报, 2017, **43**(3): 390–397)
- 35 Hosny K M, Darwish M M, Aboelenen T. Novel fractional-order generic Jacobi-Fourier moments for image analysis. *Signal Processing*, 2020, **172**: Article No. 107545
- 36 Liao Lu-Feng, Li Si-Kun, Wang Xiang-Chao. Bad spot detection method of lithography based on pre-trained VGG11 model. *Journal of Optics*, 2023, **43**(3): 140–149
(廖陆峰, 李思坤, 王向朝. 基于预训练 VGG11 模型的光刻坏点检测方法. 光学学报, 2023, **43**(3): 140–149)
- 37 Kakarwal S, Paithane P. Automatic pancreas segmentation using ResNet-18 deep learning approach. *System Research and Information Technologies*, DOI: <https://doi.org/10.20535/SRIT.2308-8893.2022.2.08>
- 38 Zhang T, Qi G J, Xiao B, Wang J D. Interleaved group convolutions. In: Proceedings of the IEEE International Conference on Computer Vision (ICCV). Venice, Italy: IEEE, 2017. 4383–4392
- 39 Mao X F, Qi G G, Chen Y F, Li X D, Duan R J, Ye S K, et al. Towards robust vision Transformer. In: Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). New Orleans, USA: IEEE, 2022. 12032–12041
- 40 Liu Z, Lin Y T, Cao Y, Hu H, Wei Y X, Zhang Z, et al. Swin Transformer: Hierarchical vision Transformer using shifted windows. In: Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV). Montreal, Canada: IEEE, 2021. 9992–10002
- 41 Wang X, Kruger U, Irwin G W. Process monitoring approach using fast moving window PCA. *Industrial and Engineering Chemistry Research*, 2005, **44**(15): 5691–5702



朱霖霖 中南大学自动化学院博士研究生. 2017 年获得南京理工大学学士学位, 2020 年获得中南大学硕士学位. 主要研究方向为先进检测技术, 图像处理和工业过程建模与监测.

E-mail: zhujilin@csu.edu.cn

(ZHU Ji-Lin Ph.D. candidate at the School of Automation, Central South University. He received his bachelor degree from Nanjing University of Science and Technology in 2017 and master degree from Central South University in 2020. His research interest covers advanced detection technology, image processing, and industrial process modeling and monitoring.)



桂卫华 中国工程院院士, 中南大学自动化学院教授. 1981 年获得中南矿业学院硕士学位. 主要研究方向为复杂工业过程建模, 优化与控制应用和故障诊断与分布式鲁棒控制.

E-mail: gwh@csu.edu.cn

(**GUI Wei-Hua** Academician of

Chinese Academy of Engineering, and professor at the School of Automation, Central South University. He received his master degree from Central South Institute of Mining and Metallurgy in 1981. His research interest covers complex industrial process modeling, optimization and control applications, and fault diagnosis and distributed robust control.)



蒋朝辉 中南大学自动化学院教授. 2011 年获中南大学博士学位. 主要研究方向为智能传感与检测技术, 图像处理与智能识别和人工智能与机器学习. 本文通信作者.

E-mail: jzh0903@csu.edu.cn

(**JIANG Zhao-Hui** Professor at the

School of Automation, Central South University. He received his Ph.D. degree from Central South University in 2011. His research interest covers intelligent sensing and detection technology, image processing and intelligent recognition, and artificial intelligence and machine learning. Corresponding author of this paper.)



陈致蓬 中南大学自动化学院副教授. 2018 年获中南大学博士学位. 主要研究方向为图像处理, 仪器检测和冶金过程建模与控制.

E-mail: ZP.Chen@csu.edu.cn

(**CHEN Zhi-Peng** Associate professor at the School of Automation,

Central South University. He received his Ph.D. degree from Central South University in 2018. His research interest covers image processing, instrument detection, and modeling and control of metallurgical process.)



方怡静 中南大学自动化学院博士研究生. 2016 年和 2019 年分别获得中南大学学士学位和硕士学位. 主要研究方向为数据驱动的工业过程建模与控制, 工业过程数据分析和机器学习.

E-mail: yijingfang@csu.edu.cn

(**FANG Yi-Jing** Ph.D. candidate

at the School of Automation, Central South University. She received her bachelor degree and master degree from Central South University in 2016 and 2019, respectively. Her research interest covers data-driven modeling and control of industrial process, data analysis of industrial process, and machine learning.)