

基于图像识别的高炉风口剩余使用寿命预测模型研究

廖哲晗^{1,2}, 武建龙^{2,3,4}, 黄俊杰³, 郭宏烈³, 徐健²

(1. 成都先进金属材料产业技术研究院股份有限公司, 四川 成都 610300; 2. 重庆大学材料科学与工程学院, 重庆 400044; 3. 首钢京唐钢铁联合有限责任公司炼铁作业部, 河北 唐山 063200; 4. 首钢集团有限公司技术研究院, 北京 100043)

摘要:高炉风口作为炉内热量的主要来源,其状态检测目前主要依赖人工经验判断,常导致损坏风口更换不及时,造成不必要的停产检修。为解决上述问题,提出了一种专为风口剩余使用寿命(Remaining Useful Life, RUL)预测的机器学习模型 BVT-RULNet,该模型采用集成学习(Ensemble Learning, EL)策略,集成三个结构相同的基分类器,每个基分类器均包含一个 VGG16 卷积神经网络(Convolutional Neural Network, CNN)前端和一个视觉 Transformer(Vision Transformer, ViT)模块。在模型训练过程中,采用基于风口完整生命周期图像构建的离散 RUL 数据集,在测试过程中,则采用独立的测试数据集。结果表明,模型在测试数据集上的评估指标表现优异,准确率、精确率、召回率和 F_1 分数分别达到 85.14%、84.70%、84.59% 和 84.64%,均优于对比模型。因此,BVT-RULNet 模型在风口 RUL 分类识别与预测方面具有较高的准确性和泛化能力,为高炉风口状态智能监测提供了有效的解决方案。

关键词:高炉;集成学习策略;风口图像数据集;风口剩余使用寿命

中图分类号:TP181,TF5

文献标志码:A

文章编号:1004-7638(2025)05-0013-10

DOI: 10.7513/j.issn.1004-7638.2025.05.002

开放科学(资源服务)标识码(OSID):



听语音
与作者互动
聊科研

Research on the remaining useful life estimation model of blast furnace tuyere based on image recognition

LIAO Zhehan^{1,2}, WU Jianlong^{2,3,4}, HUANG Junjie³, GUO Honglie³, XU Jian²

(1. Chengdu Advanced Metal Materials Industry Technology Research Institute Co., Ltd., Chengdu 610300, Sichuan, China; 2. College of Materials Science and Engineering, Chongqing University, Chongqing 400044, China; 3. Ironmaking Department, Shougang Jingtang United Iron and Steel Co., Ltd., Tangshan 063200, Hebei, China; 4. Shougang Technology Research Institute, Beijing 100043, China)

Abstract: As the primary source of in-furnace heat, the condition detection of blast furnace tuyeres mainly relies on manual experience currently. This practice often leads to delayed replacement of damaged tuyeres and unnecessary shutdown maintenance. To address the above issues, this paper proposes a machine learning model named BVT-RULNet, specifically designed to predict the Remaining Useful Life (RUL) of tuyeres. The model employs an Ensemble Learning (EL) strategy that integrates three base classifiers with identical architectures. Each base classifier consists of a VGG16 Convolutional Neural Network (CNN) frontend and a Vision Transformer (ViT) module. During model training, a discrete RUL dataset constructed based on the images covering the complete life cycle of the tuyere was used, and an independent test dataset was used during the evaluation process. Results show that the

收稿日期:2025-07-31; 修回日期:2025-09-04; 接受日期:2025-09-05

作者简介:廖哲晗, 1994 年出生, 男, 四川绵阳人, 博士, 长期从事炼铁智能化研究工作, E-mail: lzh941223@163.com。

model achieves excellent metrics on the test set, with accuracy, precision, recall, and $F1$ score reaching 85.14%, 84.70%, 84.59%, and 84.64%, respectively, all outperforming the comparison models. Therefore, BVT-RULNet model demonstrates high accuracy and strong generalization for tuyere RUL classification and prediction, providing an effective solution for intelligent monitoring of blast furnace tuyere condition.

Key words: blast furnace, ensemble learning strategy, tuyere images dataset, tuyere remaining useful life

0 引言

高炉作为一种大型逆流多相反应器,是炼铁生产的核心装备^[1-3],负责将铁矿石还原成铁水。然而,在高炉生产过程中,需要不断鼓入高温气体,从而使炉内还原、燃烧等多种化学反应进行。风口作为高炉下部鼓风的关键部件^[4],通过在风口前端形成高温“风口回旋区”^[5-6],不仅维持了高炉冶炼所需热量,同时决定了炉内气流分布的均匀性及铁水质量的稳定性^[7]。然而,高炉风口的工作环境极其恶劣,长期经受高温、高压的严峻考验,并且长期受到热应力循环^[8]、Cu-Zn 合金相生成^[9]及渣铁侵蚀^[10]等多重机制破坏。因此,恶劣的服役环境对风口的使用寿命提出了严峻的考验。通过对国内主要大型高炉风口使用寿命进行调研统计,发现风口寿命普遍较短^[11]。具体而言,沙钢 5 800 m³ 高炉风口的平均寿命仅为 79 天,首钢京唐两座 5 500 m³ 高炉风口寿命一般为 4 到 6 个月,宝钢湛江 1、2 号 5 050 m³ 高炉风口寿命约为 6 个月,宝钢四座高炉风口寿命一般为 10 到 12 个月。此外,传统的风口状态评估主要依赖操作人员的经验判断与人工巡检,难以及时发现风口状态变化,导致对风口状态的延迟响应与误判,如损坏的风口不能得到及时有效的更换,将造成不必要的停炉检修。因此,建立可靠的风口剩余使用寿命(Remaining Useful Life, RUL)^[12-14]预测模型,对于提醒风口更换、保障高炉连续稳定生产具有重要意义。

随着高炉风口图像在线监测技术的发展^[15-17],以及卷积神经网络(Convolutional Neural Network, CNN)对于图像特征提取与分类能力的提升^[18],为风口智能化识别与判断提供了新的契机。近年来,风口图像识别技术的研究主要集中在两大方向:一方面,主要集中在开发机器学习模型,如 TIDL-Net^[19]、ESERNet^[20]、LSERNet^[21]等,提高模型对风口异常状态(如风口烧损、挂渣、关风等)的识别与分类能力^[22]。另一方面,将机器学习模型应用于风口周边环境参数的预测与分析,进而从侧面判断风口的状态,如炉缸温度变化^[23]、回旋区燃烧效率^[24-26]以及

煤粉喷吹管道堵塞^[27]等问题的早期预警。

然而,当前的研究均聚焦于异常风口状态的识别与分类,没有提出对风口 RUL 早期有效的预警方案。因此,基于集成学习(Ensemble Learning, EL)策略^[28],将 CNN 与视觉 Transformer(Vision Transformer, ViT)^[29]相结合,提出了一种 BVT-RULNet 模型用于对风口 RUL 预测。将风口监测从传统的人工经验判断转变为数据驱动的自动识别,实现对风口损坏进行提前识别与预警,从而减少因风口损坏引发的高炉非计划停产风险。

1 高炉风口图像数据收集与处理

1.1 风口图像收集流程


在高炉炼铁工艺中,高炉下部区域的热空气经由热风围管输送,最终通过风口鼓入炉内,其结构示意如图 1(a)所示。为实时、全面地监控高炉风口区域的运行状态,国内某炼铁厂在风口窥视孔处部署了一套风口摄像监控系统。该系统通过高性能 CCD 摄像机^[26],可连续捕获炉内风口实时图像,为后续分析和模型训练提供可靠的视觉数据源。接着,在利用机器学习模型进行风口 RUL 预测之前,需将采集的原始视频信息转化为结构化、适用于模型训练的风口图像数据集,其构建流程如图 1(b)所示。该数据集构建过程主要包含以下步骤:首先,对连续录制的风口监控视频进行逐帧分解,提取静态图像样本;随后,对每帧提取的图像执行预处理操作(如噪声抑制、对比度调整、尺寸归一化等),从而提升图像质量、消除干扰因素,同时保证数据格式的一致性;紧接着,基于图像中风口所呈现的特征状态,对每一张预处理后的图像进行标注,赋予其对应的风口分类标签。最终,将完成标注与预处理的图像样本系统性地整合、组织,形成结构化的风口状态图像数据集。

1.2 风口图像预处理

高炉风口长期处于极端恶劣的工业环境,造成所捕获的原始风口图像普遍存在降质问题。具体表现为图像中含有大量随机噪声,并常掺杂着与风口本体无关的背景干扰信息或光学伪影。这些图像降

质因素严重影响了数据的视觉可判读性与后续分析的可靠性。因此, 为了提升图像数据的质量、增强

特征的显著性并适配后续机器学习模型的输入要求, 需对原始图像进行预处理, 具体步骤如图 2 所示。



(a) 风口分布示意; (b) 风口图像数据集处理流程

图 1 高炉风口图像收集与处理

Fig. 1 Collection and processing of blast furnace tuyere images




图 2 风口图像数据预处理流程

Fig. 2 Sequential stages of tuyere image data pre-processing

预处理流程的第一步是图像裁剪, 将视觉焦点集中在风口本体, 有效剔除图像边缘冗余的背景信息。裁剪操作以原始图像的中心为基准点, 采用固定尺寸的矩形区域进行截取, 将有效区域尺寸缩减

至 206×209 像素。裁剪之后, 执行图像尺寸调整, 使预处理后的图像尺寸与所采用的 CNN 网络的输入尺寸(224×224 像素)相兼容, 便于后续特征提取。随后, 采用最小-最大归一化法(Min-Max Normaliza-

tion)^[30], 依据公式 (1) 对图像中每个像素的强度值进行线性变换, 从而消除不同图像间可能存在的光照差异和传感器响应偏差。

$$x' = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (1)$$

式中:

x' —归一化后的像素值;

x —原始像素值;

$\min(x)$ —数据集集中的最小值;

$\max(x)$ —数据集集中的最大值。

最后, 应用高斯模糊方法^[31]对图像进行去噪处理。利用各向同性高斯函数对图像进行平滑处理, 有效去除图像中的噪声成分, 提高图像的清晰度和可读性, 如公式 (2) 所示。

$$G(\mu, v) = \frac{1}{2\pi\sigma^2} e^{-\frac{\mu^2 + v^2}{2\sigma^2}} \quad (2)$$

式中:

$r^2 = \mu^2 + v^2$ —模糊半径;

σ —高斯分布的标准差;

$G(\mu, v)$ —高斯模糊核。

1.3 风口图像增强处理

为进一步提升所构建风口图像数据集的丰富度与多样性, 同时提升机器学习模型的泛化能力与鲁棒性, 对训练数据集中的图像进行了系统化的数据增强操作, 处理流程如图 3 所示。具体而言, ①随机裁剪: 在预处理裁剪基础上, 进一步在图像有效区域内随机选取不同位置和尺寸进行二次裁剪 (范围在 0 ~ 20%); ②随机水平翻转: 以一定概率对图像进行水平镜像翻转; ③颜色扰动: 在亮度、对比度、饱和度和色调等色彩通道上施加随机、小幅度的扰动; ④随机旋转: 在预设角度范围内 ($\pm 15^\circ$) 对图像进行随机旋转; ⑤随机仿射变换: 组合应用随机平移、缩放和剪切等变换; ⑥随机擦除: 在图像中随机选择矩形区域, 并用随机值覆盖。




图 3 图像数据增强示意
Fig. 3 Schematic diagram of image data enhancement

1.4 风口数据集构建

在数据集构建阶段, 选取了五段完整覆盖风口从投入使用直至失效整个寿命周期的监控视频作为数据来源。根据风口 RUL 的衰减程度, 将风口视频的生命周期离散化划分为九个阶段, 分别对应风口 RUL 从相对较高 (90%) 到临近失效 (10%) 的完整退化轨迹, 如图 4 所示, 从图中可以看出, 在正常风口状态下, 其亮度值处于标准范围, 边缘轮廓清晰平滑, 喷枪与煤粉区域分明, 未见暗区扩散现象。随着风口 RUL 逐渐降低, 整体亮度值出现轻微下降, 边缘开始变得不光滑, 并逐渐出现黑色边缘。当风口 RUL 降至 20% 以下时, 亮度值显著下降, 边缘明显粗糙, 暗区范围明显扩大。

基于上述风口图像数据, 通过图像预处理和数据增强操作, 构建了一个结构清晰、标签完备的风

口 RUL 分类图像数据集。该数据集总计包含 18 000 张图像样本, 为确保数据在风口各阶段具有均衡代表性, 每个离散的 RUL 阶段各包含 2 000 张图像。另外, 在除上述数据以外, 构建了一个同样包含上述九个分类状态共计 4 000 张图像的独立测试数据集, 用于模型预测能力测试。






图 4 风口 RUL 九个离散阶段图像数据准备
Fig. 4 The image data preparation for nine discrete stages of tuyere RUL

2 风口 RUL 预测模型与方法

2.1 模型结构框架

采用了基于 Bagging^[32] 的集成学习策略用于模型的训练, 算法示意如图 5(a) 所示, 算法伪代码如图 5(b) 所示。在每次训练中, 使用 bootstrap 方法^[33] 将训练数据集 $\mathcal{L}$ 随机采样为多个子集 $\mathcal{L}_i$, 然后由不同的分类器 C_i 分别评估每个子集的分类结果。最终, 通过对这些分类器的输出结果进行平均, 进而获得最终的分类结果, 从而利用集体的力量来增强算法的泛化能力。



(a)算法示意; (b)算法伪代码

图 5 基于 Bagging 的集成学习算法

Fig. 5 Bagging-based ensemble learning algorithm

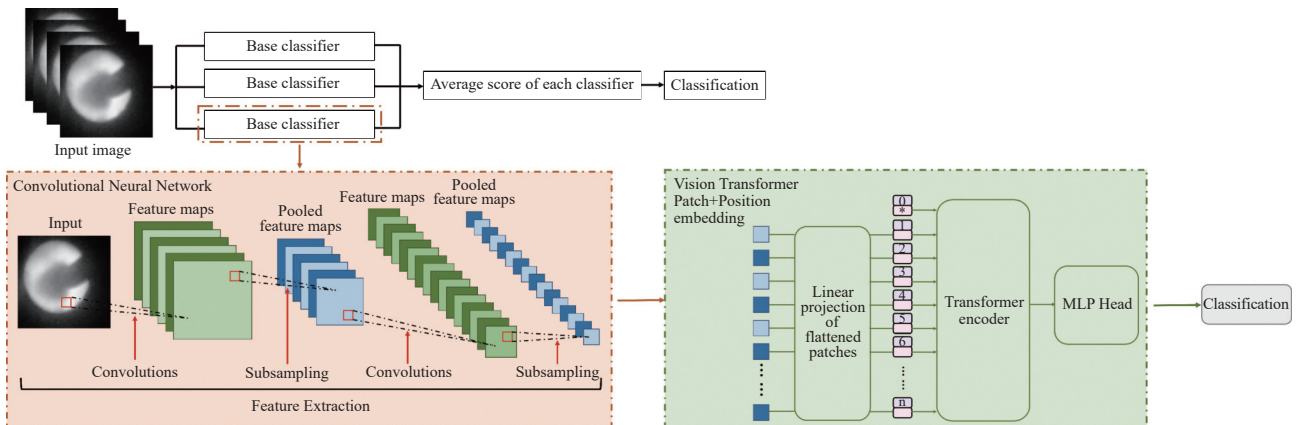


图 6 BVT-RULNet 模型框架

Fig. 6 BVT-RULNet modeling framework

2.2 CNN 模块

在 CNN 模块, 采用 VGG16 网络架构^[34], 如图 7

所示。该网络采用 13 个卷积层结构, 通过深度堆叠小型卷积核构建了层次化的特征提取框架, VGG

所示。该网络采用 13 个卷积层结构, 通过深度堆叠小型卷积核构建了层次化的特征提取框架, VGG

团队在 ImageNet 数据集上对比了不同深度模型 (VGG11/13/16/19), 发现 13 个卷积层在分类准确率与计算成本间达到最优平衡, 可提取足够抽象的特征, 同时避免过度依赖全连接层参数, 而当卷积层深度进一步加深, 带来的收益递减, 且易出现梯度不稳

定或过拟合现象。此外, 卷积层按功能划分为五个区块, 每个区块包含 2~3 个卷积层, 所有卷积核尺寸均统一使用 3×3 像素, 并在末端接入 2×2 像素最大池化层实现空间下采样, 最终将输入图像压缩为 7×7×512 维的特征张量。




图 7 VGG16 模型架构

Fig. 7 The model architecture of VGG16

2.3 ViT 模块

ViT 模型由三个主要模块组成: 图像块嵌入层、Transformer 编码器和多层感知器。

1) 图像块嵌入层

输入图片 $x \in \mathbb{R}^{H \times W \times C}$ 被分割为 $N = \frac{H \times W}{P^2}$ 个尺寸为 $P \times P$ 的图像块, 其中 H, W, C 分别为图像高度、宽度和通道数, P 为块分辨率。每个图像块 $x_p \in \mathbb{R}^{P^2 \times C}$ 通过线性投影映射为 D 维嵌入向量, 如式 (3) 所示。

$$z_p = x_p E, E \in \mathbb{R}^{(P^2 \cdot C) \times D} \quad (3)$$

其中 E 为可学习的嵌入矩阵。为保留空间信息, 添加位置嵌入 $E_{pos} \in \mathbb{R}^{(N+1) \times D}$, 如式 (4) 所示。

$$z_0 = [z_{cls}; z_p^1, z_p^2, \dots, z_p^N] + E_{pos} \quad (4)$$

此处 z_{cls} 为可学习的分类标记 (Class Token), 位于序列首位, 用于聚合全局信息。

2) Transformer 编码器

Transformer 编码器由 L 个结构相同的编码器模块依次堆叠而成, 如图 8 所示, 每个编码器块包含两个子层: 多头自注意力 (MSA) 子层和全连接前馈多层感知器 (MLP) 层。在第 l 层, 首先接收来自第 $(l-1)$ 层的输入序列 z_{l-1} , 并在特征维度上施加层归一化 (LN), 以消除内部协变量偏移并提升训练稳定性。归一化后的结果被送入 MSA 子层, 通过多头注意力机制并行捕获输入序列中的复杂依赖关系。随后, MSA 的输出再度经过层归一化处理, 最终将归一化后的输出结果传递给 MLP 子层, 进行非线性变换与特征融合。编码器模块内部的梯度传递过程见式 (5)(6)。

$$z'_l = \text{LN}(z_{l-1}) + \text{MSA}(\text{LN}(z_{l-1})) \quad (5)$$

$$z_l = \text{LN}(z'_l) + \text{MLP}(\text{LN}(z'_l)) \quad (6)$$

3) 多层感知器

最终仅提取分类标记 z_{cls}^L 作为图像表征, 通过两层多层感知器输出分类概率, 见式 (7)。

$$\hat{y} = \text{Softmax}(\text{MLP}(\text{LN}(z_{cls}^L))) \quad (7)$$

因此, ViT 模块的输入特征维度与 CNN 网络输出特征维度保持一致, 均为 512, 设置了两层编码器层, 每层编码器均包含多头自注意力机制与前馈神经网络, 其中前馈网络隐藏层维度为 2 048, 同时使用 8 个并行自注意力头。为防止过拟合, 在注意力计算前后分别引入了概率为 0.6 的 Dropout 操作。最终通过全局平均池化和全连接层输出分类结果。




图 8 Transformer 编码器块

Fig. 8 Transformer encoder block

2.4 模型性能评价指标

在模型性能评价方面, 采用混淆矩阵的方法, 通

过计算准确率、精确率、召回率以及 F_1 分数对模型在风口 RUL 分类任务中的表现进行评价。其中, 混淆矩阵如表 1 所示, 记录了预测的结果与实际结果之间的对应关系。其中, “TP” 表示真正例的数量, 即模型正确识别为正类的样本数量。“FP” 代表假正例的数量, 指的是模型错误地将负类样本预测为正类的样本数量。“FN” 表示假反例的数量, 指的是模型错误地将正类样本预测为负类的样本数量。“TN” 表示真反例的数量, 即模型正确预测为负类的样本数量。

表 1 混淆矩阵
Table 1 Confusion matrix

Actual condition	Predicted condition	
	Positive	Negative
Positive	TP	FN
Negative	FP	TN

基于混淆矩阵, 可以计算出一系列性能指标, 这些指标综合反映了分类模型在不同维度上的性能表现, 具体如式(8)~(11)所示。

1) 准确率(Accuracy): 在模型预测过程中, 所有判断正确的结果占总观测值的比重, 反映了模型正确预测样本的能力, 准确率越高, 模型的整体预测性能越好。计算公式如式(8)所示。

$$\text{Accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FN} + \text{FP}} \times 100\% \quad (8)$$

2) 精确率(Precision): 在模型预测过程中, 所有预测为正类的结果中模型预测正确的比重, 反映了模型预测正例的能力, 精确率越高, 模型预测的正例越可靠。计算公式如式(9)所示。

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \times 100\% \quad (9)$$

3) 召回率(Recall): 又称为灵敏度, 在模型预测过程中, 所有真实值是正类的结果中, 模型预测正确的比重, 反映了模型对正例的识别能力, 召回率越高, 模型遗漏的正例越少。计算公式如式(10)所示。

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \times 100\% \quad (10)$$

4) F_1 分数(F_1 Score): 召回率和精确率的调和平均数, 反映了模型的综合性能, F_1 分数越高, 模型的预测性能越均衡。计算公式如式(11)所示。

$$F_1 = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \times 100\% \quad (11)$$

此外, 论文中的模型训练和预测的计算任务均在高性能工作站上运行, 该工作站配置了 NVIDIA GeForce RTX 4090 GPU、3.7 GHz Intel Core i7 8700k CPU 以及 64 GB RAM、250 GB SSD 存储和

3 TB 硬盘空间。采用 Ubuntu 18.04 操作系统, 机器学习框架为 Pytorch 2.7.0 (<https://pytorch.org/>)。模型训练过程中, 利用随机梯度下降(Stochastic Gradient Descent, SGD)^[35] 算法进行优化, 同时应用 CrossEntropyLoss 函数(式(12))来计算预测标签与实际标签之间的损失值^[36]。


$$\text{Loss} = - \sum_{i=1}^N y_i \log \hat{y}_i \quad (12)$$

其中, y_i 为真实值, $\hat{y}_i$ 为预测结果。

3 风口 RUL 预测模型评价

3.1 风口图像特征识别能力

为评估模型特征识别能力, 图 9 展示了前四层卷积块中, 通过随机选择各层卷积块的五个通道, 对比了各通道对风口特征的提取情况。具体而言, 浅层卷积块主要聚焦于风口边缘结构等空间细节特征, 而深层网络则逐步提取更高阶的抽象语义信息。基分类器的 VGG16 模块通过局部特征增强机制对关键区域进行权重优化分配, 显著提升了局部判别性特征的提取效率。该设计使分类器能够充分挖掘图像区域细节信息, 从而有效强化特征检测能力。因此, VGG16 能够有效的对风口特征进行提取。



(a) 卷积块 0; (b) 卷积块 1; (c) 卷积块 2; (d) 卷积块 3

图 9 不同卷积块随机选择的五个通道的特征提取热图


Fig. 9 Heatmaps of feature extraction for five randomly selected channels of different convolutional blocks

3.2 风口 RUL 预测模型训练性能

在训练过程中, 同时对比了训练数据集和验证数据集上的损失函数值及分类准确性随训练迭代的变化趋势, 以评估模型的学习动态与泛化能力, 如图 10 所示。值得注意的是, 在训练过程中训练数据

集采用了预处理和数据增强技术,以提升模型的鲁棒性和泛化性能;而验证数据集则只进行了图像预处理过程,用于客观评估模型对未见数据的预测能

力。此外,为防止过拟合并优化训练效率,训练过程中采用了早停机制,当验证数据集损失值在连续 3 轮迭代中均未出现显著改善,则提前终止训练。



(a)损失值; (b)准确率对比

图 10 基于训练数据集和验证数据集的损失值和准确率对比
Fig. 10 Comparison of loss values and accuracy based on training and validation datasets

对于训练过程中损失值变化,如图 10 (a) 所示,呈现显著的单调下降趋势,从初始的 1.41 快速下降至第 8 轮的 0.59 左右,随后保持平稳,缓慢下降至 0.53 左右。验证集损失同样表现出明显的下降趋势,从 1.23 在第 17 轮达到最低值 0.41,其下降过程虽略有波动,但整体收敛态势良好。由于训练数据集应用了数据增强,因此验证数据集损失值在训练后期普遍低于训练数据集损失值。同时,在训练过程中,模型在完成第 20 轮迭代后触发了早停机制,训练自动终止。此时模型在验证集上的损失值已接近其最低值,模型已获得较优的泛化性能。其次,图 10 (b) 展示了训练数据集和验证数据集在训练迭代过程中预测准确性的变化。训练数据集准确率从初始的 41.04% 稳步提升至最终的 80.06%,增长幅度显著。验证数据集准确率则展现出更优异的性能,从 46.36% 提升至最高 84.58%,最终稳定在 83.96%。

综上所述,训练过程展示了模型在训练数据集和验证数据集上的有效学习与收敛。早停机制在模型即将达到最佳泛化状态时介入,成功防止了过拟合。数据增强的应用虽导致训练损失值略高、训练准确率略低于验证数据集,但有效提升了模型最终的泛化性能。

3.3 风口 RUL 预测准确性对比

为客观评估所提出的 BVT-RULNet 模型在风口 RUL 预测任务上的有效性,将其与三种具有代表性的模型在独立测试数据集上进行了全面的性能对

比,对比结果如图 11 所示。

首先,选择了经典的 VGG16 和 ResNet50^[34] 两种单一 CNN 模型架构作为基准。测试结果显示, VGG16 在测试数据集上的准确率为 75.92%, 精确率为 73.94%, 召回率为 75.49%, F_1 分数为 74.70%; 而 ResNet50 表现更优, 准确率、精确率、召回率和 F_1 分数分别提升至 78.25%、76.75%、79.59% 和 78.15%。与 VGG16 相比, ResNet50 在准确率上提升了 2.33 个百分点, 在 F_1 分数上提升了 3.45 个百分点, 表明更深的残差网络结构有助于提取风口 RUL 分类任务中的细粒度特征。




图 11 不同模型在测试数据集上的性能对比
Fig. 11 Performance comparison of different models on the test data set

其次,对比了将 VGG16 的特征提取与 ViT 的全局自注意力机制相结合的 VT-RULNet 模型在测

试数据集上的表现。该模型取得了 82.82% 的准确率、78.85% 的精确率、85.39% 的召回率及 81.99% 的 F_1 分数,相较于 ResNet50,准确率提升 4.57 个百分点, F_1 分数提升 3.84 个百分点;召回率更是提高了 5.80 个百分点。因此,引入自注意力机制可以有效增强模型对不同寿命阶段特征的特征能力。

最后,进一步对比了论文所提出的 BVT-RULNet 模型性能。该模型在测试集上的各项指标均达到了最优水平。其中,准确率为 85.14%、精确率为 84.70%、召回率为 84.59%、 F_1 分数为 84.64%。与单一 VT-RULNet 相比,准确率额外提升了 2.32 个百分点, F_1 分数提升了 2.65 个百分点;与 ResNet50 相比,则分别提升了 6.89 和 6.49 个百分点。

综上可得, Bagging 集成学习策略通过对多个模型结果的平均,能够有效抑制个体模型在特定样本上的过度拟合或偏差,从而在整体上提高分类性能和稳定性。同时, ViT 结构在全局特征感知方面的优势进一步增强了模型对风口多阶段 RUL 退化特征的特征能力。因此, BVT-RULNet 模型在高炉风口 RUL 分类预测任务中具有较好的性能表现,能够为实际生产中的预警与维护决策提供可靠的判断依据。

4 结论

风口是高炉的重要组成部分,它提供了观察高

炉内部的独特窗口。准确预测其 RUL 对于确保高炉的稳定运行至关重要。因此,基于集成学习策略,采用 VGG16 和 ViT 模块作为基分类器,提出了专用于风口 RUL 预测的 BVT-RULNet 模型,研究结果总结如下:

1) 采用风口实时监测图像,依据风口 RUL 的衰减程度,将风口全生命周期离散划分为九个阶段,分别对应风口 RUL 从相对较高(90%)到临近失效(10%)的完整退化轨迹,形成具有九大 RUL 分类的风口图像数据集;

2) BVT-RULNet 模型框架,采用 VGG16 模型作为前端特征提取网络,用于从风口图像中提取局部特征。随后,使用 ViT 模块将特征图分割为多个图像块,这样既保留了建立块间全局依赖关系的能力,又强化了对局部细微特征的敏感性。最后,通过多层感知器分类头输出结果,实现对风口 RUL 的有效预测;

3) 训练后的模型,在独立的测试数据集上,准确率、精确率、召回率和 F_1 分数分别达到 85.14%, 84.70%, 84.59%, 84.64%,均优于其他对比模型,对于风口 RUL 分类识别与预测具有较高的准确性和泛化能力;

4) 未来,将进一步致力于收集更大规模、更多样化的风口图像数据,同时进一步优化参数和模型,期望完全实现风口监测从传统的人工经验判断到数据驱动自动识别的转变。

参考文献

- [1] WANG G, LIAO Z H, HU Z W, *et al.* Influence of the residual iron on the erosion of carbon bricks in a 4 000 m³ blast furnace hearth: From the measured properties to the proposed mechanisms[J]. Metallurgical and Materials Transactions B, 2022: 53, 931-937.
- [2] YU X B, SHEN Y S. Transient state modeling of industry-scale ironmaking blast furnaces[J]. Chemical Engineering Science, 2022, 248: 117185.
- [3] ZHENG K, ZHAO P, HU P, *et al.* Study on the effects of oxygen enrichment modes on the tuyere raceway states of blast furnace[J]. Iron Steel Vanadium Titanium, 2024, 45(6): 108-118.
(郑魁, 赵鹏, 胡鹏, 等. 富氧方式对高炉风口回旋区状态的影响研究[J]. 钢铁钒钛, 2024, 45(6): 108-118.)
- [4] ZHANG J, WANG R, HU R, *et al.* Failure mode and mechanism of a blast furnace tuyere[J]. Engineering Failure Analysis, 2022, 137: 106294.
- [5] HUANG C C, BORN S, KLAASSEN M, *et al.* Comprehensive numerical modeling of raceways in blast furnaces[J]. Chemical Engineering Science, 2024, 289: 119857.
- [6] MA S W, QIU G B, LÜ X W, *et al.* Theoretical research on the effects of oxygen enrichment and pulverized coal injection on performance of tuyere raceway zone in blast furnace[J]. Iron Steel Vanadium Titanium, 2012, 33(4): 62-67.
(马世伟, 邱贵宝, 吕学伟, 等. 富氧喷煤对高炉风口回旋区特征影响的理论研究[J]. 钢铁钒钛, 2012, 33(4): 62-67.)
- [7] ZHOU D D, CHENG S S, ZHANG R X, *et al.* Study of the combustion behaviour and temperature of pulverised coal in a tuyere zone of blast furnace[J]. Ironmaking & Steelmaking, 2018, 45(7): 665-671.
- [8] LI G S, HUANG P Y, CHENG P, *et al.* Analysis of the failure mechanism of a blast furnace tuyere sleeve with protective coating[J]. Engineering Failure Analysis, 2023, 153: 107537.
- [9] WANG H Y, ZHANG J L, LIU Z J, *et al.* Damage mechanism of blast furnace tuyere by zinc[J]. Ironmaking & Steelmaking, 2018, 45(6): 560-565.

- [10] CHAI Y F, ZHANG J L, NING X J, *et al.* Mechanism research on melting loss of coppery tuyere small sleeve in blast furnace[J]. High Temperature Materials and Processes, 2016, 35(1): 73-80.
- [11] LEI M, DU P, ZHU H, *et al.* Influence of blasting conditioning parameters on tuyere life of shagang's 5 800 m³ BF[J]. Ironmaking, 2022, 41(3): 22-26.
(雷鸣, 杜屏, 朱华, 等. 沙钢 5 800 m³ 高炉下部调剂参数对风口寿命的影响[J]. 炼铁, 2022, 41(3): 22-26.)
- [12] GUGULOTHU N, TV V, MALHOTRA P, *et al.* Predicting remaining useful life using time series embeddings based on recurrent neural networks[J]. arXiv preprint arXiv: 1709.0107, 3: 2017.
- [13] WANG Y D, ZHAO Y F, ADDEPALLI S. Remaining useful life prediction using deep learning approaches: a review[J]. Procedia Manufacturing, 2020, 49: 81-88.
- [14] SI X S, WANG W B, HU C H, *et al.* Remaining useful life estimation – a review on the statistical data driven approaches[J]. European Journal of Operational Research, 2011, 213(1): 1-14.
- [15] PUTTINGER S, STOCKER H. Improving blast furnace raceway blockage detection. Part 1: classification of blockage events and processing framework[J]. ISIJ International, 2019, 59(3): 466-473.
- [16] PUTTINGER S, STOCKER H. Improving blast furnace raceway blockage detection. Part 2: signal processing of hot blast pressure data[J]. ISIJ International, 2019, 59(3): 474-480.
- [17] PUTTINGER S, STOCKER H. Improving blast furnace raceway blockage detection. Part 3: visual detection based on tuyere camera images[J]. ISIJ International, 2019, 59(3): 481-488.
- [18] O'SHEA K, NASH R. An introduction to convolutional neural networks[J/OL]. arXiv preprint arXiv: 2015. <https://arxiv.org/abs/1511.08458>.
- [19] LI Q, WANG Z J, WANG S, *et al.* A deep learning-based diagnosis model driven by tuyere images big data for iron - making blast furnaces[J]. Steel Research International, 2022, 93(8): 2100826.
- [20] WANG R H, LI Z Y, YANG L Z, *et al.* Application of efficient channel attention residual mechanism in blast furnace tuyere image anomaly detection[J]. Applied Sciences, 2022, 12(15): 7823.
- [21] SONG C, LI Z Y, LI Y M, *et al.* Research on blast furnace tuyere image anomaly detection, based on the local channel attention residual mechanism[J]. Applied Sciences, 2023, 13(2): 802.
- [22] ZHOU B, YE H, ZHANG H F, *et al.* Process monitoring of iron-making process in a blast furnace with PCA-based methods[J]. Control Engineering Practice, 2016, 47: 1-14.
- [23] CUI G M, JIANG Z G, LIU P L, *et al.* Prediction of blast furnace temperature based on multi-information fusion of image and data[C]// 2018 Chinese Automation Congress (CAC). Xi'an: 2018: 2317-2322.
- [24] LIU B N, WU M H. Intelligent modeling of tuyere raceway of blast furnace[C]// 2021 33rd Chinese Control and Decision Conference (CCDC). Kunming: 2021: 5466-5471.
- [25] LIU Y R, ZHANG H M, SHEN Y S. A data-driven approach for the quick prediction of in-furnace phenomena of pulverized coal combustion in an ironmaking blast furnace[J]. Chemical Engineering Science, 2022, 260: 117945.
- [26] ZHOU D D, XU K, BAI J Y, *et al.* On-line detecting the tuyere coke size and temperature distribution of raceway zone in a working blast furnace[J]. Fuel, 2022, 316: 123349.
- [27] WANG Y T, HUANG P, YANG G. A visual PCI blockage detection in blast furnace raceway[J]. ISIJ International, 2020, 60(3): 519-527.
- [28] DONG X B, YU Z W, CAO W M, *et al.* A survey on ensemble learning[J]. Frontiers of Computer Science, 2020, 14(2): 241-258.
- [29] DOSOVITSKIY A, BEYER L, KOLESNIKOV A, *et al.* An image is worth 16 x16 words: transformers for image recognition at scale[J]. arXiv preprint arXiv: 2010.1192, 9: 2020.
- [30] PATRO S, SAHU K. Normalization: a preprocessing stage[J]. arXiv preprint arXiv: 1503.0646, 2: 2015.
- [31] KUMAR B. Image denoising based on gaussian/bilateral filter and its method noise thresholding[J]. Image and Video Processing, 2013, 7: 1159-1172.
- [32] GUO Y Y, WANG X, XIAO P C, *et al.* An ensemble learning framework for convolutional neural network based on multiple classifiers[J]. Soft Computing, 2020, 24(5): 3727-3735.
- [33] BREIMAN L. Bagging predictors[J]. Machine Learning, 1996, 24(2): 123-140.
- [34] MASCARENHAS S, AGARWAL M. A comparison between VGG16, VGG19 and ResNet50 architecture frameworks for image classification[C]// 2021 International Conference on Disruptive Technologies for Multi-Disciplinary Research and Applications (CENTCON). Bengaluru: 2021: 96-99.
- [35] NEWTON D, YOUSEFIAN F, PASUPATHY R. Stochastic gradient descent: recent trends[J]. Recent Advances in Optimization and Modeling of Contemporary Problems, 2018, 193-220.
- [36] ZHANG Z L, SABUNCU M. Generalized cross entropy loss for training deep neural networks with noisy labels[C]// 2018 32nd Conference on Neural Information Processing Systems (NeurIPS), Montréal: 2018:31.