

# 基于多轨迹门控循环单元的车轮故障检测算法

梅佳锐, 王月明, 杨虎生, 陈 龙

(内蒙古科技大学 自动化与电气工程学院, 内蒙古 包头 014010)

**摘要:** 烧结机台车轴承的弯曲和断裂等故障会导致车轮脱落, 进而影响烧结机台车的正常运行。针对目前台车轴承故障检测中存在的信号干扰大、检测环境差、实时性低等问题, 本文提出了一种基于多轨迹门控循环单元 (GRU) 与多头注意力机制的车轮卡顿和摆动检测算法, 以此来判定轴承是否发生故障。首先, 搭建烧结机台车车轮卡顿和摆动检测平台, 利用目标检测算法绘制螺栓的实际运动轨迹; 然后, 将获得的螺栓轨迹坐标按照连续帧裁剪为相同帧数的轨迹坐标片段, 并分为正常轨迹片段、卡顿轨迹片段和摆动轨迹片段; 最后, 利用所构建的多轨迹 GRU 与多头注意力机制模型对正常轨迹、卡顿轨迹和摆动轨迹进行分类, 并对比所构建的其他循环神经网络模型的结果, 选择最优模型进行轴承故障检测。为验证该方法的可行性, 在台车车轮检测平台上进行测试。试验表明, 本文所提出的多轨迹 GRU 与多头注意力机制模型的准确率为 90.38%, 比所构建的其他循环神经网络模型表现更优, 能够准确地检测出发生卡顿与摆动的车轮, 为台车轴承故障自动化检测提供有效解决方案。

**关键词:** 车轮卡顿和摆动; 循环神经网络; 轴承故障; 异常检测

**中图分类号:** TF046.4; TP183; U279

**文献标志码:** A

**文章编号:** 1000-8764(2025)05-0027-08

**doi:** 10.13403/j.sjqt.2025.05.075

## Wheel fault detection algorithm based on multi-trajectory gated recurrent unit

MEI Jiarui, WANG Yueming, YANG Husheng, CHEN Long

(School of Automation and Electrical Engineering, Inner Mongolia University of Science & Technology, Baotou 014010, Inner Mongolia, China)

**Abstract:** Faults such as bending and breaking of the bearing of the sintering machine trolley will cause the wheels to fall off, which in turn will affect the normal operation of the sintering machine trolley. Aiming at such problems as large signal interference, poor detection environment and low real-time performance in the current bearing fault detection of trolleys, a wheel stuttering and swing detection algorithm based on multi-trajectory gated recurrent unit (GRU) and multi-head attention mechanism is proposed to determine whether the bearing has failed. Firstly, a wheel stuttering and swing detection platform of sintering machine trolley is built, and the actual motion trajectory of the bolt is drawn by using the object detection algorithm. Then, the obtained bolt trajectory coordinates are clipped into trajectory coordinate fragments with the same number of frames according to continuous frames, and divided into normal trajectory fragments, stuttering trajectory fragments and swing trajectory fragments. Finally, the constructed multi-trajectory unit and multi-head attention mechanism model are used to classify the normal trajectory, stuttering trajectory and swing trajectory, the classification results of other recurrent neural network models are compared, and the optimal model is selected for bearing fault detection. In order to verify the feasibility of the method, it is tested on the trolley wheel detection platform. Experiments show that the accuracy

**收稿日期:** 2025-03-39; **修回日期:** 2025-05-09

**基金项目:** 内蒙古自治区科技计划项目(2021GG0045); 内蒙古自治区高等学校科学研究项目(NJZY21400)

**作者简介:** 梅佳锐(1999—), 男, 硕士研究生, 从事计算机视觉检测、故障检测方面的研究。

**通信作者:** 王月明(1978—), 男, 教授, 从事计算机智能科学与技术方面的研究。

of the multi-trajectory unit and multi-head attention mechanism model proposed in this paper is 90.38%, which is better than other recurrent neural network models constructed, and can accurately detect the wheels that stutter and swing, providing an effective solution for the automatic detection of bearing failures in trolleys.

**Key words:** wheel stuttering and swing; recurrent neural network; bearing failure; anomaly detection

烧结过程是高炉炼铁的前置工序,可为冶金生产提供所需的优质原料<sup>[1-2]</sup>。烧结机作为这一过程的核心设备,在其运行过程中由台车周期性运输烧结矿<sup>[3]</sup>。由于烧结机台车长期在高温、重载和高浓度粉尘的恶劣环境下不间断运行,需要定期给轴承加注润滑油,否则长期的磨损会导致车轮轴承出现断裂或弯曲等故障,进而引发车轮卡顿或摆动现象<sup>[4]</sup>。如果未能及时发现并对故障车轮进行维修,可能导致车轮脱落,进而引发生产事故<sup>[5]</sup>。目前,烧结机台车的轴承故障检测主要依赖人工巡检。然而,由于台车车轮数量庞大且工作环境恶劣,人工检测方式存在安全隐患问题以及存在劳动强度大、易漏检误检等问题<sup>[6]</sup>。因此,进行烧结机台车轴承的自动化故障检测研究,对于确保烧结矿制造过程的有序、协调、高效和连续生产具有重要的安全性和经济意义<sup>[7]</sup>。

常见的轴承故障检测方法包括基于振动信号、声发射信号和热成像技术<sup>[8]</sup>。李恒亮等<sup>[9]</sup>使用基于振动信号的检测方法提出了一种基于 SPA 和 IRCMMPE 的旋转机械损伤识别方法。佟鑫宇等<sup>[10]</sup>使用基于声发射信号的检测方法对滚动轴承故障进行诊断。然而,由于台车车轮在低速重载的条件下运行,基于振动信号和声发射信号的方法难以有效采集到足够的信号<sup>[11]</sup>。此外,由于烧结机所处环境复杂且车轮数量众多,所需的检测设备数量庞大,导致上述方法在实际工况下难以进行故障诊断。

近年来,基于计算机视觉的故障检测方法因其具备非接触、高效率和良好的环境适应性等优点在机械设备中得到了广泛应用,并逐步应用于轴承故障研究<sup>[12-13]</sup>。例如,利用高速摄像头捕捉轴承的旋转状态,并结合图像处理技术来检测异常运动轨迹<sup>[14]</sup>;通过深度学习模型分析采集的图像,识别轴承裂纹、磨损等典型故障特征<sup>[15]</sup>。这些方法为烧结机台车车轮轴承的故障检测提供了一种可行的解决方案。

针对烧结机台车车轮轴承故障人工检测时存在安全隐患问题以及存在劳动强度大、易漏检误检等问题,提出了一种基于计算机视觉的车轮卡顿和摆动检测方案。当烧结机台车车轮轴承发生弯曲或断裂等故障时,台车车轮会出现卡顿和摆动现象。根据这一现象,本文通过搭建烧结机台车车轮卡顿和摆动检测平台,采集车轮侧面实时运行视频,训练 YOLOv9 目标检测模型获得螺栓的运动轨迹,构建一种结合多轨迹门控循环单元(gated recurrent unit,GRU)与多头注意力机制的螺栓轨迹分类模型,并对比所构建的其他循环神经网络模型验证模型的性能,最终根据轨迹的分类结果检测车轮的卡顿与摆动,实现轴承的故障检测。

## 1 卡顿和摆动检测总体方案

根据烧结机台车的运行状况,搭建烧结机台车车轮卡顿和摆动检测平台并制定烧结机台车车轮卡顿和摆动检测方案,如图 1 所示。

(1) 故障平台搭建和螺栓目标检测:分别布置一台工业相机在台车的两侧,使其正对车轮,高度和车轮轴心保持一致,并且和车轮之间保持固定的距离;在车轮进入检测区域后,使用固定好的工业相机采集车轮的侧面视频图像数据;在构建好的车轮目标螺栓数据集上训练 YOLOv9 目标检测模型,并采用不同于数据集中的车轮运行视频测试模型,最终实现螺栓目标的实时检测。

(2) 螺栓轨迹坐标获取:基于训练好的 YOLOv9 目标检测模型,实时检测并输出螺栓的边界框坐标;通过边界框中心点计算获取螺栓实时位置后,使用最近邻匹配算法对多帧检测结果进行数据关联,生成同一螺栓的连续运动轨迹。将获得的 6 个螺栓的轨迹坐标按照连续帧裁剪为相同帧数的轨迹坐标片段,并分为正常轨迹片段和卡顿和摆动轨迹片段。

(3) 卡顿和摆动检测算法构建:首先,构建一种结合多轨迹 GRU 与多头注意力机制的螺栓

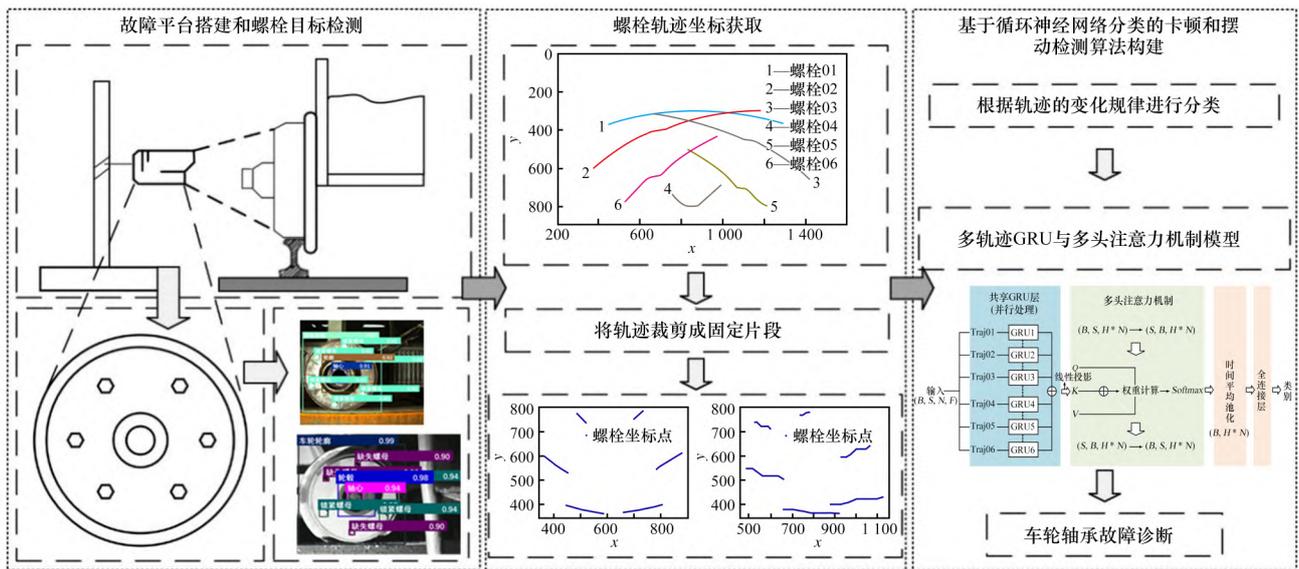


图 1 烧结机台车卡顿和摆动检测总体方案

Fig. 1 Overall scheme for detecting jamming and swaying faults in the sintering machine trolley

轨迹分类模型, 用于螺栓运动轨迹分类; 利用标注的螺栓轨迹坐标数据集训练该模型。随后, 使用训练完成的模型对运动轨迹数据集进行自动分类, 并对比所构建的其他循环神经网络的分类精度验证模型性能; 最终, 根据轨迹的分类结果判断车轮是否出现卡顿和摆动现象。

## 2 螺栓目标检测

### 2.1 YOLOv9 网络

在工业场景下, 目标检测模型的精度是故障检测的关键因素。YOLOv9 引入了可编程梯度信息 (PGI) 机制和广义高效层聚合网络 (GELAN) 架构, 有效缓解了深层网络中的信息丢失问题, 并通过可靠的梯度更新提升了模型训练效果<sup>[16]</sup>。PGI 通过辅助可逆分支生成可靠的梯度信息, 改善训练过程中梯度传播质量。GELAN 融合了跨阶段部分网络 (CSPNet) 和高效层聚合网络 (ELAN) 的优势, 实现了高效的特征融合和参数利用率。性能对比显示 YOLOv9 在 MS COCO 数据集上的目标检测性能超过了 YOLOv7 等其他目标检测模型。综上所述, YOLOv9 拥有高精度、轻量化和鲁棒性等方面的优势, 选择 YOLOv9 作为烧结机台车卡顿和摆动检测的目标检测模型。

### 2.2 数据集制作和模型训练

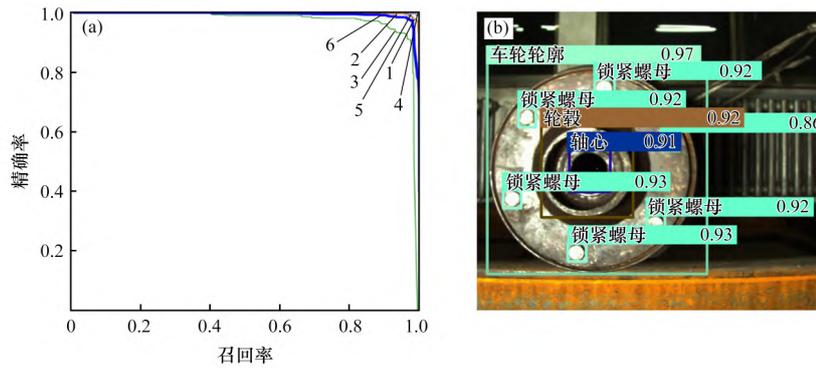
螺栓的目标检测具体步骤包括: (1) 通过工

业摄像头采集车轮的运行视频, 将视频裁剪成帧图像用于制作数据集; (2) 采用 YOLOv9 作为目标检测模型, 使用 LabelImg 对帧图像进行标注, 构建车轮目标螺栓数据集, 共制作车轮子部件数据集 743 张; (3) 将标注后的图像和标签文件随机分为训练集和测试集, 比例为 8:2; (4) 在构建好的车轮目标螺栓数据集上训练 YOLOv9 目标检测模型; (5) 在车轮进入检测区域后, 使用训练好的模型检测螺栓在视频图像中的坐标位置。YOLOv9 模型训练结果如图 2 所示。

图 2 中, 子图 (a) 为模型在验证集上得到的 PR 曲线, 子图 (b) 为目标检测的效果图。使用 YOLOv9 模型对车轮各部件进行训练, 训练后锁紧螺栓的精确率为 99.60%, 缺失螺栓的精确率为 97.40%, 所有类别的平均精确率为 99.20%。YOLOv9 目标检测模型获得的螺栓目标框将用于后续螺栓轨迹坐标的获取。

## 3 螺栓轨迹坐标获取

在完成螺栓的目标检测后, 利用螺栓目标检测框获得螺栓运动轨迹。具体步骤: ① 计算 6 个螺栓坐标框的中心坐标; ② 通过最近邻匹配方法获得同一螺栓的中心坐标; ③ 将得到的螺栓轨迹坐标裁剪成相同帧数的轨迹片段, 并将其分为正常轨迹片段和异常轨迹片段, 构建轨迹坐标数据集。



(a) YOLOv9 模型训练过程中的 PR 曲线; (b) 车轮子部件目标检测效果  
1—车轮轮廓(0.996); 2—锁紧螺母(0.996); 3—缺失螺母(0.974); 4—轮毂(0.997);  
5—轴心(0.997); 6—所有类别(0.992 mAP@0.5)。

图 2 YOLOv9 模型训练与检测结果

Fig. 2 Results of YOLOv9 model training and test

### 3.1 螺栓中心坐标获取

在完成螺栓和轴心的目标检测后, 首先获取每个螺栓目标框的左上角和右下角的坐标, 即每个螺栓的左上角坐标 $(x_{\text{bolt}_i-l}, y_{\text{bolt}_i-l})$ 和右下角坐标 $(x_{\text{bolt}_i-r}, y_{\text{bolt}_i-r})$ ,  $\text{bolt}_i-l$ 代表 6 个螺栓目标框的左上角的坐标,  $\text{bolt}_i-r$ 代表 6 个螺栓目标框的右下角的坐标, 其中 $1 \leq i \leq 6$ 。为了得到螺栓的中心位置坐标, 求取两个对角顶点坐标的  $x$  轴和  $y$  轴的平均值。中心坐标表达式如公式(1)所示。

$$\begin{cases} x_{\text{bolt}_i} = \frac{x_{\text{bolt}_i-r} + x_{\text{bolt}_i-l}}{2} \\ y_{\text{bolt}_i} = \frac{y_{\text{bolt}_i-r} + y_{\text{bolt}_i-l}}{2} \end{cases} \quad (1)$$

式中:  $x_{\text{bolt}_i}$ 和 $y_{\text{bolt}_i}$ 表示第  $i$  个螺栓中心点的坐标。这一过程的目的是将螺栓的目标框转换为其中中心点坐标, 便于后续轨迹跟踪和分类。

### 3.2 螺栓坐标的身份匹配

为了获得车轮上同一螺栓的轨迹坐标, 利用最近邻匹配原则对邻近两帧图像中的螺栓坐标进行匹配, 从而获得同一螺栓对应的所有轨迹坐标, 并按照时间顺序进行排列, 匹配过程如下。

计算相邻两帧每个螺栓中心坐标两两之间的距离, 距离计算公式如式(2)所示。

$$D_{ij} = \sqrt{(x_{\text{bolt}_i}^n - x_{\text{bolt}_j}^{n+1})^2 + (y_{\text{bolt}_i}^n - y_{\text{bolt}_j}^{n+1})^2} \quad (1 \leq i, j \leq 6) \quad (2)$$

式中:  $D_{ij}$ 是前一帧和后一帧螺栓坐标的欧氏距离

计算结果;  $x_{\text{bolt}_i}^n$ 和 $y_{\text{bolt}_i}^n$ 是前一帧中螺栓  $\text{bolt}_i$  的纵横坐标;  $x_{\text{bolt}_j}^{n+1}$ 和 $y_{\text{bolt}_j}^{n+1}$ 是后一帧中螺栓  $\text{bolt}_j$  的纵横坐标。在计算完中心坐标距离后, 将计算得到的 $D_{ij}$ 值最小的两个坐标认定为同一螺栓的中心坐标。

### 3.3 坐标数据集的制作

当完成了螺栓中心坐标的获取和身份匹配, 接下来的任务是把这些轨迹数据整理为数据集, 供后续的训练和测试使用。将每一帧图像中的螺栓中心坐标作为一个数据点, 结合对应的时间信息和标签, 形成一个完整的轨迹数据集。由于每一个烧结机车车轮有 6 个螺栓, 当车轮经过检测区域后, 每个数据样本包含 6 个螺栓的轨迹坐标, 数据结构( $\mathbf{D}$ )如式(3)所示。

$$\mathbf{D} = [(x_{\text{bolt}_1}^1, y_{\text{bolt}_1}^1), \dots, (x_{\text{bolt}_1}^n, y_{\text{bolt}_1}^n), \dots, (x_{\text{bolt}_6}^1, y_{\text{bolt}_6}^1), \dots, (x_{\text{bolt}_6}^n, y_{\text{bolt}_6}^n), k_{\text{label}}] \quad (3)$$

式中:  $x_{\text{bolt}_i}^n, y_{\text{bolt}_i}^n$ 是每一帧图像中螺栓的中心坐标;  $n$ 是每个螺栓  $\text{bolt}_i$ 的轨迹片段的长度, 由于车轮是匀速运行,  $n$ 根据车轮的运行速度设置,  $k_{\text{label}}$ 为轨迹的标签, 当 $k_{\text{label}} = 0$ 时轨迹为正常轨迹, 当 $k_{\text{label}} = 1$ 时轨迹为异常轨迹。

图 3 为车轮进入检测区域后, 螺栓中心坐标的轨迹示意。该图展示了一条轨迹坐标点在笛卡尔平面上的分布情况  $x$  轴和  $y$  轴分别表示轨迹的水平 and 垂直维度, 总共有 300 个坐标点, 每个点以蓝色标出, 反映了轨迹数据的空间分布特征。

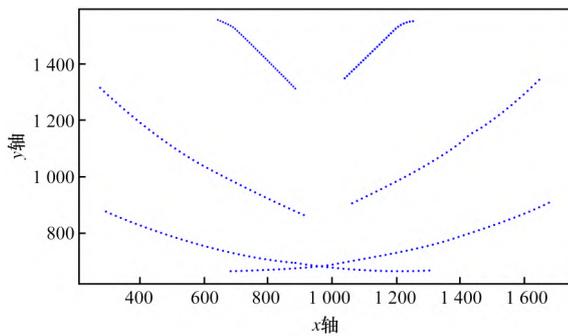


图 3 螺栓轨迹坐标示意

Fig. 3 Schematic diagram of bolt trajectory coordinates

#### 4 基于循环神经网络分类的卡顿和摆动检测算法构建

在完成螺栓轨迹坐标数据集制作后, 为了实现烧结机台车车轮卡顿和摆动检测, 提出了一种用于螺栓轨迹分类的多轨迹 GRU 与多头注意力机制模型。将轨迹分为了正常轨迹和异常轨迹, 其中异常轨迹包括了卡顿轨迹和摆动轨迹, 利用构建好的螺栓运动轨迹数据集在台车车轮卡顿和摆动检测平台上训练多轨迹 GRU 与多头注意力机制模型, 对比 GRU、Bi-LSTM 和多轨迹 Bi-LSTM 与多头注意力机制模型几种常见的循环神经网络模型, 并观察车轮的卡顿或摆动情况, 来确定用于车轮卡顿和摆动检测的算法。最终根据轨迹的分类结果从而判断车轮是否出现卡顿和摆动现象, 试验表明, 该算法能够有效完成烧结机台车轴承的故障检测。

##### 4.1 车轮的卡顿和摆动

在车轮运行过程中, 车轮轴承滚子的丢失或断裂会导致车轮轴承松动、转速变慢或者停止旋转, 车轮会出现卡顿和摆动。车轮卡顿和摆动示意如图 4 所示。

通过观察车轮的实际运行状况和螺栓的轨迹变化, 来确定车轮的卡顿与摆动情况。当车轮正常运行时, 由车轮螺栓的运动轨迹为一条平滑的曲线, 如图 4 中正常轨迹①所示; 当车轮出现卡顿时, 螺栓的运动轨迹如图 4 中异常轨迹②中的红色轨迹片段所示, 当车轮出现摆动时, 螺栓的运动轨迹如图 4 中异常轨迹③中的黄色轨迹片段所示; 因此, 可以通过分析螺栓的轨迹来判断车轮是否出现卡顿和摆动; 将螺栓轨迹分为正常轨迹、异常轨迹, 利用构建好的多轨迹 GRU 与多头

注意力机制模型对轨迹进行分类, 并对比所构建的循环神经网络模型分类结果, 选择合适的模型进行轴承故障检测。

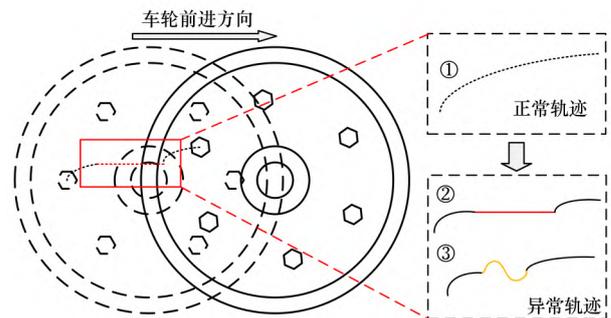


图 4 车轮卡顿和摆动示意

Fig. 4 Schematic diagram of wheel jamming and swaying faults

##### 4.2 多轨迹 GRU 与多头注意力机制模型

基于上述车轮的卡顿和摆动情况分析, 构建一种多轨迹 GRU 与多头注意力机制轨迹分类模型。GRU 是一种改进的递归神经网络(RNN), 其引入的门控机制能够有效避免传统 RNN 在处理长序列时所出现的梯度消失或爆炸问题<sup>[17]</sup>。相比长短期记忆网络(LSTM), GRU 结构更加简单, 计算资源消耗较低。

多头注意力机制是一种在 Transformer 模型中广泛应用的机制, 用于处理输入序列中不同位置之间的关系。其核心思想是通过多个注意力头并行地对输入数据进行加权求和, 从而捕捉不同的上下文信息<sup>[18]</sup>。通过引入多头注意力机制, 模型能够在多个子空间中并行地关注输入序列的不同方面, 从而增强对复杂模式的学习能力<sup>[19]</sup>。

多轨迹 GRU 与多头注意力机制模型结构图如图 5 所示。提出了一种结合多轨迹 GRU 和多头注意力机制的模型, 用于螺栓轨迹的分类。该模型首先使用 GRU 处理每条轨迹的时间序列数据, 通过提取每条轨迹的隐藏状态来捕捉时间依赖性。接着, 模型将多个轨迹的 GRU 输出拼接在一起, 形成一个整体特征表示。为了进一步加强不同轨迹间的信息交互, 模型引入了多头注意力机制, 允许不同轨迹之间的特征加权融合。最终, 模型通过全连接层进行分类, 输出车轮卡顿或摆动的故障判断。

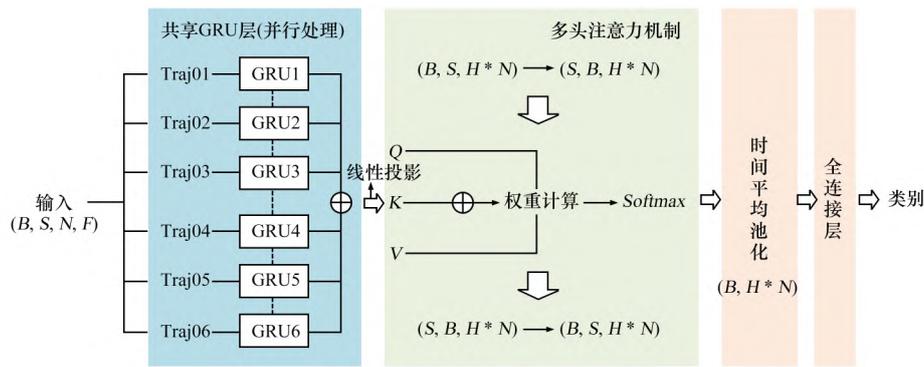


图 5 多轨迹 GRU 与多头注意力机制模型结构

Fig. 5 Structural diagram of multi-trajectory GRU with multiple attention models

在图 5 中: Traj01 ~ Traj06 为 6 个螺栓的轨迹;  $B$  为单次传递时训练参数的个数;  $S$  为时间步长;  $N$  为轨迹的数量;  $F$  为特征维度;  $H$  为 GRU 层的隐藏状态维度;  $Softmax$  为数学函数, 将注意力得分映射为概率分布, 从而对不同轨迹的重要性进行归一化加权。通过这种结构, 模型能够在多个轨迹之间进行有效的信息共享和融合, 充分利用多头注意力机制增强不同轨迹间的交互性, 从而提高故障检测的准确性。

#### 4.3 车轮卡顿和摆动检测试验

为了验证所提检测算法的有效性, 设计螺栓运动轨迹分类试验。工业相机通过 GigE 接口分别连接到训练平台和检测平台, 以传输数据。

通过采集车轮的实时运行视频构建螺栓轨迹坐标数据集(总计 756 条数据), 将数据集随机分为训练集和验证集, 并将轨迹坐标数据集分为正常轨迹片段和异常轨迹片段; 其中训练集中有 580 条数据, 其中正常轨迹片段有 290 条, 异常轨迹片段有 290 条(异常轨迹片段中, 摆动轨迹 208 条, 卡顿轨迹 82 条, 轻微的卡顿或者摆动共 40 条); 验证集中有 104 条数据, 其中正常轨迹片段有 52 条, 异常轨迹片段有 52 条(异常轨迹片段中, 摆动轨迹 38 条, 卡顿轨迹 14 条, 轻微的卡顿或者摆动有 7 条); 测试集中有 72 条数据, 其中正常轨迹片段有 36 条, 异常轨迹片段有 36 条(异常轨迹片段中, 摆动轨迹 25 条, 卡顿轨迹 11 条, 轻微的卡顿或者摆动有 5 条); 数据集及结构如表 1 所示。

使用所提出的多轨迹 GRU 与多头注意力机制模型进行训练, 在训练的过程中计算训练的损失

表 1 轨迹坐标数据集

Table 1 Trajectory coordinate dataset

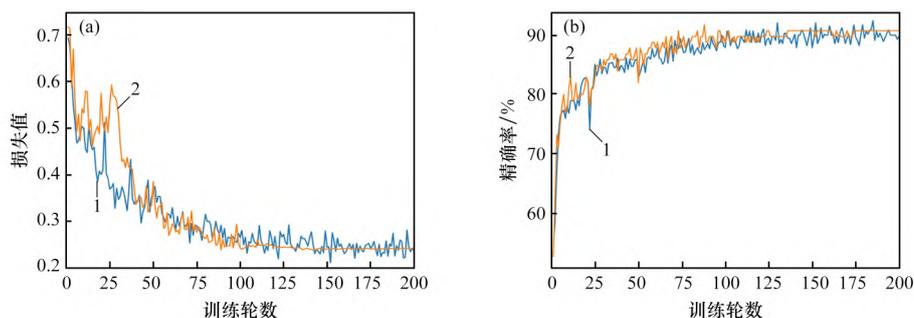
数据类型	训练集/条	验证集/条	测试集/条
正常轨迹片段	290	52	36
异常轨迹片段	290	52	36
总数据集	580	104	72

和准确率, 同时在验证集上评估模型并计算验证损失和准确率, 在完成多轨迹 GRU 与多头注意力机制模型的训练后, 在准备好的测试集上对模型进行最终的评估并计算损失和准确率。多轨迹 GRU 与多头注意力机制模型训练的损失和准确率如图 6 所示。

由图 6 可知, 在训练的过程中, 训练集和验证集的准确率均趋于 90%, 训练集和验证集的损失值均趋于 0.25, 训练集和验证集的准确率和损失非常接近, 模型收敛良好, 且无明显的过拟合或欠拟合现象; 模型在测试集上的准确率达到 90.38%, 损失值为 0.242 6, 模型的整体性能较好, 能够实现正常轨迹、卡顿轨迹和摆动轨迹的分类。

为了进一步验证所提多轨迹 GRU 与多头注意力机制模型的有效性, 将其与以下模型进行对比: GRU、Bi-LSTM、多轨迹 Bi-LSTM 与多头注意力机制模型, 不同模型在测试集上的准确率如表 2 所示。图 2 中,  $F_1$  为精确率与召回率的调和平均数, 用于综合评估模型性能。

由表 2 可知, 基于多轨迹 GRU 与多头注意力机制模型(MT-GRU-MHA)在螺栓运动轨迹分类任务中性能优于所提的其他模型。在相同数据集下, 多轨迹 GRU 与多头注意力机制模型的准确率达到



(a) 训练集和验证集 Loss 曲线; (b) 训练集和验证集准确率

1—训练集; 2—验证集。

图 6 多轨迹 GRU 与多头注意力机制模型训练效果

Fig. 6 Training performance diagram of the multi-trajectory GRU and multi-head attention model

表 2 模型对比结果

Table 2 Model comparison results %

模型类型	准确率	精确率	召回率	$F_1$ 值
GRU	75.96	76.20	75.96	75.91
Bi-LSTM	80.77	83.17	80.77	80.41
多轨迹 Bi-LSTM 与 多头注意力机制模型	83.65	84.69	83.65	83.53
多轨迹 GRU 与 多头注意力机制模型	90.38	90.93	90.38	90.35

90.38%,  $F_1$  值(精确率与召回率的调和平均数, 用于综合评估模型性能)为 90.35%, 分别比传统 GRU 模型提升 14.42% 和 14.44%。相比之下, Bi-LSTM 模型准确率为 80.77%, 同样引入注意力机制的多轨迹 Bi-LSTM 模型准确率为 83.65%, 均低于多轨迹 GRU 与多头注意力机制模型。

根据测试集数据的观测结果, 当车轮出现明显的卡顿或摆动现象时, 不存在误检或漏检的情况; 若车轮仅出现轻微卡顿或摆动, 螺栓的轨迹变化较小, 轴承故障概率较低。针对此类情况, 单次检测可能因噪声干扰导致误检或漏检。由于烧结机台车循环运行, 同一车轮可多次经过检测区域。在实际工况中, 可以通过多次采集车轮的运行视频序列, 并记录车轮所对应的侧板编号, 基于文中所提算法进行多次分析, 结合统计方法, 整合检测结果, 从而降低误检率, 提升卡顿和摆动的检出率。

## 5 结论

为了提高烧结生产的安全性与可靠性, 降低

因轴承故障而引起的经济损失, 提出了基于计算机视觉的烧结机台车车轮卡顿和摆动检测算法, 得出如下结论。

(1) 利用目标检测算法绘制螺栓的实际运动轨迹, 将轨迹制作成循环神经网络分类模型数据集, 将获得的螺栓轨迹坐标按照连续帧裁剪为相同帧数的轨迹坐标片段, 并分为正常轨迹片段、卡顿轨迹片段和摆动轨迹片段。

(2) 构建用于螺栓运动轨迹坐标分类的循环神经网络模型, 使用训练好的模型对正常轨迹、卡顿轨迹和摆动轨迹进行分类; 根据螺栓轨迹的分类结果判断车轮是否出现卡顿或摆动现象, 进而判断轴承故障。

(3) 通过对比所构建的其他循环神经网络模型的检测效果, 所提出的多轨迹 GRU 与多头注意力机制模型的准确率为 90.38%, 较优于 GRU、Bi-LSTM 和多轨迹 Bi-LSTM 与多头注意力机制模型; 在台车循环往复的运行过程中, 所提方法能够有效完成车轮的卡顿或摆动检测, 为轴承故障自动化检测提供可行的方案。

## 参考文献:

- [1] 易正明, 邵慧君. 基于过程参数控制的烧结矿质量预测模型[J]. 矿冶工程, 2018, 38(6): 92-96.  
YI Zhengming, SHAO Huijun. A prediction model for sintering quality based on control of process parameters [J]. Mining and Metallurgical Engineering, 2018, 38(6): 92-96.
- [2] 庄清云, 李光石, 鲁雄刚, 等. 360 m<sup>2</sup> 烧结机节能降耗关键技术研究及应用[J]. 钢铁, 2025, 60(4): 13-20.

- ZHUANG Qingyun, LI Guangshi, LU Xionggang, et al. Research and application of key energy-saving and consumption reducing technologies for 360 m<sup>2</sup> sintering machine [J]. *Iron & Steel*, 2025, 60(4): 13–20.
- [3] 张昊, 陈波, 梅佳锐, 等. 基于改进 DeepLabv3+ 的烧结机车轮摆动检测算法研究 [J]. *烧结球团*, 2025, 50(1): 31–37.
- ZHANG Hao, CHEN Bo, MEI Jiarui, et al. Research on wheel swing detection algorithm of sintering machine based on improved DeepLabv3+ [J]. *Sintering and Pelletizing*, 2025, 50(1): 31–37.
- [4] 李圭文, 陈永春, 李建东. 韶钢 360 m<sup>2</sup> 烧结机提高产量生产实践 [J]. *烧结球团*, 2017, 42(3): 12–15.
- LI Guiwen, CHEN Yongchun, LI Jiandong. Practice of improving 360 m<sup>2</sup> sinter strand production in SGIS Songshan Co., Ltd. [J]. *Sintering and Pelletizing*, 2017, 42(3): 12–15.
- [5] 杨虎生, 王月明, 张昊, 等. 烧结机台车缺陷部件在线智能检测系统设计与实现 [J]. *烧结球团*, 2024, 49(4): 10–18.
- YANG Husheng, WANG Yueming, ZHANG Hao, et al. Design and realization of online intelligent detection system for defective parts of sintering machine trolley [J]. *Sintering and Pelletizing*, 2024, 49(4): 10–18.
- [6] 董岱, 方实年, 卫卫, 等. 烧结台车车轮润滑油自动加注装置设计及试验 [J]. *液压与气动*, 2021(1): 146–151.
- DONG Dai, FANG Shinian, WEI Wei, et al. Design and test of automatic lubricating oil filling device for sintering trolley wheels [J]. *Chinese Hydraulics & Pneumatics*, 2021(1): 146–151.
- [7] WANG D J, WU S L, LI C X, et al. Efficient and clean production practice of large-scale sintering machine [J]. *ISIJ International*, 2013, 53(9): 1665–1672.
- [8] 徐潇, 宋冬利, 王梓帆. 基于改进 SAE(堆叠自编码器)与温振融合的高速列车轴箱轴承轻微故障诊断方法 [J]. *城市轨道交通研究*, 2025, 28(4): 227–232.
- XU Xiao, SONG Dongli, WANG Zifan, et al. High-speed train axle box bearing slight fault diagnosis method based on improved SAE and temperature-vibration fusion [J]. *Urban Mass Transit*, 2025, 28(4): 227–232.
- [9] 李恒亮, 张思婉, 郭衡. 基于 SPA 和 IRCMMPE 的旋转机械损伤识别方法 [J]. *机电工程*, 2025, 42(6): 1045–1054.
- LI Hengliang, ZHANG Siwan, GUO Heng. Damage identification method of rotating machinery based on SPA and IRCMMPE [J]. *Journal of Mechanical & Electrical Engineering*, 2025, 42(6): 1045–1054.
- [10] 佟鑫宇, 沙云东, 栾孝驰, 等. 基于声发射特征参数与波形流分析的滚动轴承故障诊断方法 [J]. *科学技术与工程*, 2024, 24(30): 13180–13188.
- TONG Xinyu, SHA Yundong, LUAN Xiaochi, et al. Fault diagnosis method of rolling bearing based on acoustic emission characteristic parameters and waveform flow analysis [J]. *Science Technology and Engineering*, 2024, 24(30): 13180–13188.
- [11] 冉文静, 赵晓顺, 霍晓静, 等. 振动监测及减振技术在耕整地机械的应用研究 [J]. *中国农机化学报*, 2022, 43(6): 32–42.
- RAN Wenjing, ZHAO Xiaoshun, HUO Xiaojing, et al. Research on the application of vibration monitoring and vibration reduction technology in cultivated land preparation machinery [J]. *Journal of Chinese Agricultural Mechanization*, 2022, 43(6): 32–42.
- [12] 刘巍, 李肖, 马鑫, 等. 采用复合式靶标的近景大视场相机标定方法 [J]. *红外与激光工程*, 2016, 45(7): 230–236.
- LIU Wei, LI Xiao, MA Xin, et al. Camera calibration method for close range large field of view camera based on compound target [J]. *Infrared and Laser Engineering*, 2016, 45(7): 230–236.
- [13] 陈国君, 陈鹏, 张学军. 基于计算机视觉的轴承表面缺陷检测 [J]. *煤矿机械*, 2009, 30(2): 189–190.
- CHEN Guojun, CHEN Peng, ZHANG Xuejun. Inspection on bearing surface defect based on computer vision [J]. *Coal Mine Machinery*, 2009, 30(2): 189–190.
- [14] YANG J Z, TSE P. Sparse representation of complex steerable pyramid for machine fault diagnosis by using non-contact video motion to replace conventional accelerometers [J]. *Measurement*, 2021, 175: 109104.
- [15] 胡翔坤, 李华, 冯毅雄, 等. 基于深度学习的基础设施表面裂纹检测方法研究进展 [J]. *计算机工程与应用*, 2025, 61(1): 1–23.
- HU Xiangkun, LI Hua, FENG Yixiong, et al. Research advance of crack detection for infrastructure surfaces based on deep learning [J]. *Computer Engineering and Applications*, 2025, 61(1): 1–23.

(下转第 84 页)

4 种炭化工艺中一段炭化(方案 4)生物质炭的燃烧性能更好,燃烧反应更容易。

(3) 生物质炭-焦粉混合燃烧时主要分为两个阶段:低温区时以生物质炭燃烧为主的“燃烧阶段 I”,高温区以焦粉燃烧为主的“燃烧阶段 II”。并且生物质炭-焦粉混合燃烧比焦粉燃烧有更低的着火点、峰值温度、燃尽温度和非等温燃烧反应活化能,燃烧性能更好。

### 参考文献:

- [1] 何志军,盛宏沅,高立华,等. 利用生物质能实现低碳炼铁的研究进展[J]. 钢铁,2025,60(1):1-14.  
HE Zhijun, SHENG Hongyuan, GAO Lihua, et al. Research progress on utilizing biomass energy to achieve low-carbon ironmaking [J]. Iron & Steel, 2025, 60(1): 1-14.
- [2] WANG Yihan, HE Xi, JIANG Feng. The energy conservation and emission reduction potentials in China's iron and steel industry: Considering the uncertainty factor [J]. Journal of Cleaner Production, 2023, 413: 137519.
- [3] 魏汝飞,朱玉龙,龙红明,等. 生物质铁矿球团研究现状与展望[J]. 烧结球团,2022,47(1):29-37.  
WEI Rufeif, ZHU Yulong, LONG Hongming, et al. Research status and prospect of biomass iron ore pellets [J]. Sintering and Pelletizing, 2022, 47(1): 29-37.
- [4] VIJAY V, KAPOOR R, SINGH P, et al. Sustainable utilization of biomass resources for decentralized energy generation and climate change mitigation: A regional case study in India [J]. Environmental Research, 2022, 212: 113257.
- [5] 周彦名,王娇月,王诗云,等. 我国生物质资源能源开发利用潜力评估[J]. 生态学杂志,2024,43(9):2702-2713.  
ZHOU Yanming, WANG Jiaoyue, WANG Shiyun, et al. Assessment of biomass resources for energy use potential in China [J]. Chinese Journal of Ecology, 2024, 43(9): 2702-2713.
- [6] SEO M W, JEONG H M, LEE W J, et al. Carbonization characteristics of biomass/coking coal blends for the application of bio-coke [J]. Chemical Engineering Journal, 2020, 394: 124943.
- [7] XU R S, DENG S L, WANG W, et al. Structural features and combustion behaviour of waste bamboo chopstick chars pyrolysed at different temperatures [J]. BioEnergy Research, 2020, 13(2): 439-451.
- [8] HADEY C, ALLOUCH M, ALAMI M, et al. Preparation and characterization of biochars obtained from biomasses for combustible briquette applications [J]. The Scientific World Journal, 2022, 2022(1): 2554475.
- [16] WANG C Y, YEH I H, MARK LIAO H Y. YOLOv9: Learning what you want to learn using programmable gradient information [M]. Computer Vision-ECCV 2024. Cham: Springer Nature Switzerland, 2024: 1-21.
- [17] 周建国,周路明,王剑宇,等. 基于优化分解与误差修正的光伏发电功率预测[J]. 太阳能学报, 2024, 45(7): 502-509.  
ZHOU Jianguo, ZHOU Luming, WANG Jianyu, et al. Pv power forecasting based on optimal decomposition and error correction [J]. Acta Energiæ Solaris Sinica, 024, 45(7): 502-509.
- [18] 张璋,常亮,田明华,等. 基于 CATPCA 的优化 Transformer 卫星电源消耗时序预测研究[J]. 北京理  
工大学学报, 2023, 43(7): 744-754.  
ZHANG Zhang, CHANG Liang, TIAN Minghua, et al. Power consumption time series forecast based on CATPCA for optimal transformer satellite [J]. Transactions of Beijing Institute of Technology, 2023, 43(7): 744-754.
- [19] 蒋亚楠,郑林枫,许强,等. 机理引导下的阶跃型滑坡位移预测深度学习模型[J]. 测绘学报, 2024, 53(6): 1128-1139.  
JIANG Yanan, ZHENG Linfeng, XU Qiang, et al. Step-like displacement prediction of landslides guided by deformation mechanism [J]. Acta Geodaetica et Cartographica Sinica, 2024, 53(6): 1128-1139.

(上接第 34 页)