

基于改进 DDNet 的皮带输送机位移故障诊断研究

高飞

(广西现代职业技术学院 信息工程学院, 广西 河池 547000)

摘要: 针对煤矿带式输送机皮带位移故障诊断中存在局限性大、耗时长的问题, 将故障数据进行多源异构处理, 并在数据处理的基础上将边缘检测算法与深度细节网络, 构建了一种结合边缘检测算法与改进深度细节网络的多源异构数据故障诊断模型; 首先利用边缘检测算法提取输送机图像中的边缘特征, 然后结合多源异构数据, 并通过改进后的深度细节网络进行故障识别, 并构建故障诊断模型; 结果表明检测模型在皮带边缘图像数据处理的检测准确率平均值为 95.27%, 比目标检测算法和 K 最邻近分类算法的准确率高出了 5.34% 和 10.21%; 同时检测模型的图像数据查全率平均值为 93.46%, 比目标检测算法和 K 最邻近分类算法的查全率高出了 4.09% 和 7.18%; 这说明研究构建的多源异构数据故障诊断模型能够显著提升皮带位移检测的可靠性和鲁棒性, 具有重要的研究价值和实际应用前景。

关键词: DDNet 网络; 皮带输送机; 机器视觉模块; 多源异构数据; 位移故障

Research on Displacement Fault Diagnosis of Belt Conveyor Based on Improved DDNet

GAO Fei

(School of Information Engineering, Guangxi Modern Vocational and Technical College, Hechi 547000, China)

Abstract: In response to the limitations and long time consumption for the belt displacement fault of belt conveyors in coal mines, this paper investigates the multi-source heterogeneous processing of fault data. Based on the data processing, a multi-source heterogeneous data fault detection model is constructed by combining edge detection algorithm and improved deep detail network. Firstly, the edge detection algorithm is used to extract edge features from conveyor images, then combines the multi-source heterogeneous data, and recognizes the fault by the improved deep detail network, and then constructs the fault detection model. The results show that the average detection accuracy of the detection model in the processing of belt edge image data is 95.27%, which is 5.34% and 10.21% higher than the accuracy of the object detection algorithm and K-nearest neighbor classification algorithm. Meanwhile, the average image data recall rate of the simultaneous detection model is 93.46%, which is 4.09% and 7.18% higher than the recall rates of the object detection algorithm and K-nearest neighbor classification algorithm. The results show that the multi-source heterogeneous data fault detection model can significantly improve the reliability and robustness of belt displacement detection, and has important research value and practical application prospects.

Keywords: DDNet network; belt conveyor; machine vision module; multi source heterogeneous data; displacement fault

0 引言

皮带输送机作为煤矿运输系统的核心装备, 其稳定性和安全性对煤炭生产至关重要。托辊作为输送机上数量众多的基础旋转与支撑部件, 一旦发生故障可能会诱发严重事故^[1]。因此, 对托辊进行健康检测具有重要的现实意义。传统的人工巡检方法效率低且安全性差, 而自检托辊的概念提供了一种新的检测思路, 通过在托辊内部安装无线传感器节点来采集并无线传输温度与振动信号^[2-3]。

国内外学者针对旋转体发电问题已经开展了大量的研究工作, 并提出了多种创新的能量收集器设计方案。例如, 文献 [4] 致力于开发基于压电材料的无源自调谐能量收集器, 以及电磁式振动能量采集装置等。与此同时, 文献

[5] 指出, 振动和声学测量是当前监控托辊状况的常用手段。然而, 现有技术在实际应用中仍面临一些挑战^[6-7]。一些设计可能因体积过大或功率不足, 难以满足自检托辊无线传感器节点的能量收集需求^[8-10]。在传统的煤矿带式输送机故障诊断领域, 主要依赖人工巡检和基于经验的判断^[11-12]。这些方法不仅效率低下, 而且由于人为因素的存在, 很容易出现误判和漏判的情况^[13-14]。随着煤炭生产规模的不断扩大以及自动化程度的日益提高, 对故障诊断的准确性和实时性的要求也在不断提高^[15-16]。显然, 传统方法已无法满足现代工业对高效率和高可靠性的需求。

针对现有技术的不足, 研究提出了一种基于改进 DDNet 网络的煤矿带式输送机位移故障诊断模型。该模型结合

收稿日期: 2024-05-13; 修回日期: 2024-05-30。

基金项目: 2024 年度广西高校中青年骨干教师科研基础能力提升项目(2024KY1486)。

作者简介: 高飞(1977-), 女, 大学本科, 副教授。

引用格式: 高飞. 基于改进 DDNet 的皮带输送机位移故障诊断研究[J]. 计算机测量与控制, 2024, 32(8): 47-54.

边缘检测算法和多源异构数据处理技术,旨在提高皮带位移故障的检测准确性和鲁棒性。研究首先介绍了改进 DD-Net 网络的研究背景和动机,然后详细阐述了模型构建的方法和步骤,包括数据采集、预处理、特征提取和故障诊断等环节。最后,通过仿真实验验证了所提模型的性能,并与现有技术进行了对比分析,展示了模型在提高故障检测效率和降低误判率方面的显著优势。

1 皮带故障诊断模型构建

1.1 皮带位移检测研究

煤矿带式输送机是煤矿生产企业中的重要设备,当煤矿带式输送机皮带发生位移时,即皮带跑偏,这会对煤矿生产造成多方面的不利影响。因此,需要对煤矿带式输送机皮带位移问题应高度重视,及时进行调整和检修,确保皮带正常运行,保障生产效率和安全生产。研究在机器视觉中利用边缘检测算法对带式输送机皮带位移进行检测。边缘检测算法能够对皮带的边缘信息进行分析 and 提取,并通过左右两条标记线对皮带位置进行实时监测^[17-18]。在进行皮带边缘检测时,首先需要对收集到的带式输送机皮带图像进行预处理。研究对图像中的信息进行红、绿、蓝 3 个变量的区分,同时每个变量对应的通道数据范围为 0~255。进行图像处理时,研究将灰度图作为计算的基础,根据图像中不同元素的饱和度来表示物体的颜色信息。通过对不同煤矿带式输送机工作环境的统计发现,该设备所处的工作环境均为光线较暗的区域,且色彩并没有过多的变化。因此研究利用加权法对 RGB 图像变量进行分析,并对其进行图像灰度的转换,转换的过程可用公式 (1) 定义:

$$H_{grey}(x,y) = \alpha R(x,y) + \beta G(x,y) + \gamma B(x,y) \quad (1)$$

式中, H 表示图像灰色转换, R 、 G 、 B 分别表示图像中红色、绿色和蓝色像素在图像中的数值, α 、 β 、 γ 分别表示 3 种颜色进行灰度转换通道的加权因子, x 、 y 分别表示 3 种颜色在对应坐标系中的坐标值。在皮带图像处理的流程中,预处理步骤完成后,研究就能够利用 Canny 算子来精确检测边缘信息。研究选择 Canny 算子的原因是其具有图像滤波、增强和检测的多种功能,能够在单一操作中实现复杂边缘的准确提取。Canny 算子通过高斯平滑滤波,对图像进行滤波操作,利用高斯滤波中的像素块与卷积核的运算就能对高斯滤波进行计算,计算过程如公式 (2) 所示:

$$e = S \cdot A \quad (2)$$

式中, e 表示高斯滤波操作, S 表示归一化的高斯滤波核, A 表示输入的图像数据。高斯滤波核在图像处理中具有重要作用,研究利用高斯滤波核计算完成后,便能进一步进行图像的梯度与方向分析。图像梯度与方向分析能够直接反映了图像中像素强度的变化率。通过对图像中的每个像素点进行梯度计算,就能够识别出像素值发生显著变化的位置,这些位置往往对应着图像的边缘信息。边缘信息是图像中重要的特征之一,它对于图像的理解和分析具有重要意义。因此,研究通过梯度计算来确定边缘信息,就能够精准地检测出图像中对应的边缘特征。图像平面中 x 、 y

方向的梯度值可用公式 (3) 表示:

$$\begin{cases} G_x = \begin{bmatrix} 1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix} \cdot A \\ G_y = \begin{bmatrix} 1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{bmatrix} \cdot A \end{cases} \quad (3)$$

式中, G_x 和 G_y 分别表示矩阵中图像像素点在 x 、 y 方向上的坐标值。得到梯度值后就能利用一阶导数信息计算对应像素点的梯度值和方向,像素点可用公式 (4) 计算:

$$G = \sqrt{G_x^2 + G_y^2} \quad (4)$$

式中, G 表示像素点信息; G_x^2 表示图像平面像素点对应 x 轴上的值; G_y^2 表示图像平面像素点对应 y 轴上的值。此时像素点的方向可用公式 (5) 计算:

$$\theta = \arctan(G_y/G_x) \quad (5)$$

式中, θ 表示像素点方向;在计算梯度值与方向的过程中,研究针对每个像素点都进行精细的梯度极大值分析。这一步骤不仅仅是为了计算每个像素点的梯度值,更重要的是为了找到梯度变化最为显著的区域,即边缘点。通过这种方法,系统能够更准确地识别图像中的边缘信息,有效区分出背景与前景,从而提高边缘检测的精度。梯度极大值分析不仅能够提升图像处理的效率,也为后续的目标识别、图像分割等任务提供了更为可靠的数据支持。

1.2 皮带边缘特征提取研究

当进行梯度值对比时,如果某像素点的梯度值超过预设的皮带运行阈值,那么该点就被认定为皮带的边缘点。反之,若梯度值未达到这一阈值,该点则被排除在边缘点之外。这种边缘点的判断方法,提供了一种有效的方式,来确定图像中哪些像素点真正代表了皮带的边缘^[19-20]。通过借助 Canny 算子对图像进行滤波处理、信息增强和边缘检测,研究能够精确地提取出图像中皮带的边缘信息。基于 Canny 算子得到的图像区域特征信息如图 1 所示。




图 1 基于 Canny 算子得到的图像区域特征信息

结合图 1 发现,利用 Canny 算子处理图像虽然能够获取到丰富的区域特征信息,但其中不可避免地会掺杂一些干扰因素。为了进一步提升皮带边缘检测的准确性,研究将霍夫变换应用于皮带边缘图像信息的处理中。霍夫变换的独特之处在于它能够有效剔除图像中的线段干扰信息,而对图像的原始特征影响甚微,实现了图像质量的优化与增强。在处理皮带图像时,由于图像信息主要呈现为平面特征,研究在平面上建立了直角坐标系,这使得霍夫变换

能够更加精准地应用于皮带边缘的检测中。通过这种方法,能够更加清晰地识别出皮带的边缘信息,为后续的分析判断提供了更为准确的数据支持,此时图像中直线信息可用公式(6)定义:

$$y_p = kx_p + b \quad (6)$$

式中, y_p 表示坐标系中对应的坐标 y 轴信息, k 表示该坐标系中直线的斜率, x_p 表示坐标系中对应 x 轴信息, b 表示坐标系中 y 轴的截距值。利用霍夫变换能够对图像中直线信息进行转换,转换后斜率与截距的关系可用公式(7)表示:

$$b = -kx_p + y_p \quad (7)$$

通过霍夫变换后,在直角坐标系中的图像为一条线,通过转换能够将图像中的每个检测点变为一条线,这些线在坐标系中都能产生一个交点。利用霍夫变换能够有效地提取到皮带图像中的边缘信息。图 2 为基于霍夫变换特征提取后的皮带边缘示意图。




图 2 基于霍夫变换特征提取后的皮带边缘示意图

1.3 皮带位移值计算

在利用霍夫变换提出图像中的多余信息后,研究就能够对皮带位移值进行计算。在图像处理领域,对图像中的多余信息进行剔除,并精确计算特定元素的位移值,是一个复杂但重要的任务。当涉及带式输送机皮带位移值的计算时,研究利用边缘检测算法对图像进行处理,以准确找到带式输送机托辊的位置。边缘检测算法通过检测图像中亮度变化剧烈的区域来定位托辊的边界,从而帮助系统识别托辊。然而,图像中往往包含许多与托辊无关的信息,这些信息可能会干扰到托辊的识别和位移值的计算。为了解决这个问题,研究利用霍夫变换来识别图像中的直线和圆等形状,通过这一特征,可以准确地确定皮带两侧托辊的个数和位置。当托辊的个数和位置确定以后,就能将这些信息标注在图像平面坐标系中。研究将左侧和右侧的托辊用图像平面坐标系进行标注,标注的过程可用公式(8)表示:

$$\begin{cases} O_n = (x_n, y_n) \\ O'_n = (x'_n, y'_n) \end{cases} \quad (8)$$

式中, O_n 表示左侧托辊, O'_n 表示右侧托辊, x_n, y_n 表示左侧托辊在坐标系中的对应值, x'_n, y'_n 表示右侧托辊在坐标系中的对应值。在精确识别出皮带左右两侧托辊的位置后,可以根据皮带在同一时刻、同一位置是否出现向左或向右的偏移情况,来全面评估整条皮带在运行过程中是否发生了位移。在深入探讨皮带位移现象时,研究发现,带式输送机的皮带位移可能会出现一种复杂的区域性位移模式。为了准确捕捉皮带区域位移的情况,研究将皮带细分

为前段、中段和后段 3 个部分,以便更精确地观察和分析每一部分的位移特性。在实际的输送过程中,输送机皮带会出现前段向右位移,中段正常,后段向左位移,或者前段向左位移,中段正常,后段向右位移的情况。为了有效地解决该问题,研究将成对的托辊作为研究对象,通过成对的托辊,可以分析左右两侧托辊与皮带之间的相对位置关系,从而判断皮带是否出现了区域性位移。在进行区域性皮带位移判断时,研究将皮带边缘检测的阈值引入到位移检测中,利用阈值来判断皮带的运行情况,判断过程可用公式(9)表示:

$$Q = \frac{\text{Max}(LO_n, L'O_n)}{LO_n + L'O_n} \cdot 100\% \quad (9)$$

式中, Q 表示判断定义, LO_n 表示左侧皮带边缘值, $L'O_n$ 表示右侧皮带边缘值。这种评估方法的核心在于精确捕捉和分析两侧托辊与皮带之间的空间关系。一旦皮带在运行过程中相对于托辊的位置发生显著变动,就能够迅速识别并判定皮带发生了位移。这样不仅能够有效预防了因皮带位移可能引发的生产事故,还确保了皮带在最佳工作状态下持续运行。通过对输送机皮带位移值的技术能够提升生产效率和安全性,减少不必要的停机时间和维护成本。

2 改进 DDNet 网络研究

在利用边缘检测算法对带式输送机皮带是否发生位移的判断后发现,该方法的检测精度和稳定性还存在一定的不足,对部分微小的位移无法准确进行捕捉和分析。为了确保皮带位移故障的有效检测,研究在利用多源异构数据的基础上引入了 DDNet 网络用于带式输送机皮带位移故障诊断模型的构建。研究中的多源异构数据来源分别是输送带左右两侧托辊的监测数据和图像数据。左右两侧托辊的监测数据包括皮带振动值、温度值和左右两侧托辊间的距离值;图像数据为皮带的位移值。通过对相关文献的分析发展,在带式输送机的多源异构数据处理过程中,温度和距离值变化都相对较缓慢,利用现有方法能够有效地完成数据提取。但皮带的振动值仅通过 DDNet 进行分析的难度较大,因此研究将煤矿带式输送机皮带振动信号与数据频率进行转换,转换过程中利用的是快速傅里叶变换(FFT)。FFT 应用于振动信号,实现时域至频域的转换,并提取频域中的故障特征,这些特征随后作为深度学习模型 DDNet 的输入。FFT 同样用于信号去噪,通过频域滤波器设计抑制噪声,优化信号质量。DDNet 网络结构中可集成特定层以处理频域数据,学习其中的频域特征。通过特征融合技术,结合时域与频域特征,将 FFT 得到的频域特征与原始时域数据一同输入至 DDNet 网络,以此提升故障诊断的准确度。

通过转换研究保留了最大频率值,并将其作为用于分析的特征数据,以此完成振动值的提取与分析。基于快速傅里叶变换处理后的皮带振动值变换如图 3 所示。

结合图 3 分析, N 通常指的是信号在时域中被采样的点数,即信号被数字化成的离散数据点的总数。 P 作为比




图 3 基于快速傅里叶变换处理后的皮带振动值变换示意图

例系数，用于在 FFT 处理过程中调整或标准化信号的幅度，或者是在频域中解释振动信号时用于缩放的系数。 P 乘以 FFT 的输出，来得到最终的振动值，这些振动值反映了皮带在不同频率下的振动强度。皮带振动值的采集通常是在皮带输送机的托辊或皮带本身上安装振动传感器。利用快速傅里叶变换进行转换的过程可用公式 (10) 表示：

$$X(m) = \sum_n^{N-1} x(n) \cdot e^{(2\pi m/N)n} \quad (10)$$

式中， $X(m)$ 表示转换后的信号频率序列， $x(n)$ 表示转换过程中输入的频率时间序列， N 表示序列中的离散信号的数量， n 表示离散信号对应的编号信息， m 表示频域信号的编号信息。在皮带运输系统的故障诊断中，快速准确地分析托辊的振动信号对于诊断潜在问题至关重要。通过快速傅里叶变换，研究可以将托辊产生的复杂时域振动信号迅速转换为频率域信息，转换过程能够凸显出信号中不同频率分量的强度和分布，从而显著提升数据分析的准确性和效率。完成振动信号的频率域转换后，研究将改进后的 DDNet 网络引入到皮带位移检测的模型构建。改进后的 DDNet 网络能够进一步优化网络结构和算法，更精确地处理和分析数据，从而能够深入分析频率信息以及数据之间的关联性，准确识别出对应的故障点。虽然构建足够多的网络层数可以提升信息处理的精确度，但过多的网络层也会增加计算的复杂性和时间成本，进而影响故障诊断的效率。因此，在构建改进 DDNet 网络时，还需要权衡精确度和效率之间的关系，找到一个适宜的网络层数。因此需要构建一个适宜的网络层数来满足要求，确定网络层数的过程能够用公式 (11) 定义：

$$Y = (W \cdot X) \circ X \quad (11)$$

式中， Y 为数据预测输出值， W 为网络层的权值参数值， X 为输入网络的向量初始值， \circ 为向量元素乘法。

3 位移检测结合改进 DDNet 网络的故障诊断模型构建

为了确保改进 DDNet 网络在皮带位移故障诊断中的可靠性，研究深入探索了数据补偿处理技术。研究发现单纯依靠位移值作为输入数据不足以反映皮带运行的全面情况。因此，研究创新地将皮带振动值、温度值以及左右两侧托

辊间的距离值等多源异构数据纳入考虑范围，通过数据补偿对这些数据进行预处理。这些经过补偿处理的数据作为改进 DDNet 网络的输入值，不仅丰富了网络的输入信息，也提高了网络对皮带运行状态的感知能力。同时研究还建立了与这些输入值相对应的隐藏层，这些隐藏层通过复杂的权重和激活函数，能够学习到输入数据中的深层特征，并据此做出准确的位移故障判断。图 4 为基于改进 DDNet 构建的多源异构数据故障诊断模型流程图。

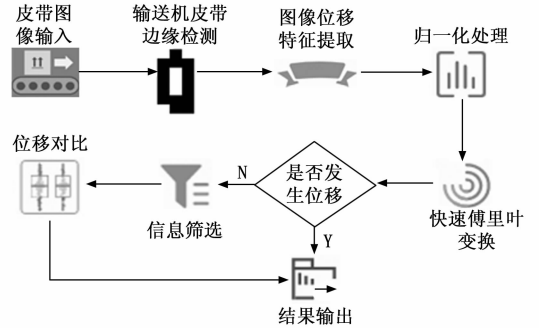


图 4 基于改进 DDNet 构建的多源异构数据故障诊断模型流程图

如图 4 所示，皮带输送机位移故障诊断流程涉及以下关键步骤：首先，皮带图像被输入系统进行边缘检测，以确定皮带边缘；其次，提取与位移相关的图像特征，并进行归一化处理；然后，通过快速傅里叶变换对特征进行频域分析，以识别皮带位移；接着，系统对比位移特征与正常状态，判断是否发生位移；若检测到位移，进一步筛选信息以确定位移原因；最后，输出故障诊断结果，包括位移检测结果、位移程度及建议的维护措施。

在进行归一化之前，还需要对皮带的位移值进行精确估算。由于斜率异常可能导致数据误差，因此在坐标系中需要对皮带位移进行校正，引入了极坐标系定义方法。在进行归一化处理前需要在坐标系中对皮带的位移值进行估算，以解决斜率异常导致的误差。研究将皮带位置进行极坐标系定义，将其位置定义为直线，此时定义可用公式 (12) 表示：

$$\rho = x' \cos\theta + y' \sin\theta \quad (12)$$

式中， ρ 表示坐标系中原点到皮带直线的垂直距离值， x' 和 y' 分别表示极坐标系中的横轴和纵轴； θ 表示横轴与垂直距离之间的夹角。在极坐标系中，选择映射最大值作为一种策略，能有效减少斜率异常带来的不利影响。通过优化数据分布，使得数据点在极坐标系中的分布更加均匀，从而降低了斜率异常出现的概率。在完成极坐标系的分布后，为了确定皮带图像边缘位移的具体情况，研究引入了非极大值抑制来对边缘细节进行细化处理。非极大值抑制是将 θ 的变化范围缩减至四分之一扇区，此时扇区的值可用公式 (13) 计算：

$$\zeta = \text{Sector}[\theta(i, j)] \quad (13)$$

式中， ζ 表示扇区值，Sector 表示皮带图像扇区对应的编号， $\theta(i, j)$ 表示在图像像素矩阵第 i 行和第 j 列时的夹角。非极大值的图像细化可用公式 (14) 进行定义：

$$K = \text{NMS}[M(i, j), \zeta(i, j)] \quad (14)$$

式中, K 表示图像细化值, NMS 为非极大值抑制, $M(i, j)$ 表示极坐标系中图像的第 i 行和第 j 列对应幅值。通过相关研究发现, 虽然对皮带图像进行了高斯滤波核处理能够提升一定的性能, 使得图像的边缘信息更加清晰, 但在皮带位移图像非极大值处理过程中, 部分位移图像的纹理和噪声仍然可能产生假边缘位移段, 这些假边缘位移段会干扰到准确的位移计算和故障诊断。为了解决假边缘位移段, 研究将双阈值化引入到图像边缘纹理的处理中。双阈值化能够通过设定两个阈值来区分强边缘、弱边缘和非边缘区域, 即一个较高的阈值用于检测确信度较高的强边缘, 而一个较低的阈值则用于检测可能存在的弱边缘。在研究中, 设定非极大值处理的阈值为 1 个, 即一个固定的数值, 用于确定哪些像素值应该被认为是边缘的一部分。所有低于这个阈值的像素值被赋予为 0, 即被视为非边缘区域, 从而有效地去除了由于噪声和纹理产生的假边缘位移段。同时, 高于阈值的像素值则被保留下来, 作为可能的边缘候选点。通过上述操作, 在模型训练过程中, 改进 DDNet 网络由于其前向传播的特性, 浅层网络的参数变化会直接影响到整个网络的输出值。而输出值作为衡量模型性能的重要指标, 其稳定性直接决定了模型训练的难易程度。因此, 为了降低模型训练的难度, 研究采用归一化处理。通过归一化处理, 图像特征信息的分布和输入问题得到了有效解决, 使得每一层网络的数据分布都保持一致。归一化处理能够确保模型训练处于一个平稳的状态, 从而降低模型训练的难度。进行归一化处理首先需要对图像中特征值进行均值化处理, 处理过程可用公式 (15) 定义:

$$\hat{c} = \frac{c - E(c)}{\sqrt{\text{Var}(c) + \epsilon}} \quad (15)$$

式中, \hat{c} 表示均值, c 表示归一化处理前的图像特征, $E(c)$ 表示归一化处理前的平均值, $\sqrt{\text{Var}(c) + \epsilon}$ 表示归一化处理时的标准差, ϵ 表示系数值。通过归一化处理, 可以显著增强梯度变化的稳定性和可预测性。这一步骤在模型训练中至关重要, 它使得梯度在训练过程中的变化更加平稳, 避免了因数据分布不均导致的训练波动。在训练开始阶段, 由于归一化的作用, 模型可以容忍一个较大的学习率, 从而加速训练过程。这不仅提高了训练效率, 还使得模型更快地收敛到最优解。为了提升诊断模型的性能, 研究设计了皮带位移实验数据采集条件, 如图 5 所示。



(a) 皮带原始位置 (b) 皮带左移诊断设置 (c) 皮带右移诊断设置

图 5 皮带位移实验数据采集条件

图 5 中设定了皮带正常使用和左移、右移时的诊断条件, 通过上述操作、数据收集, 以及对模型的优化和处理,

研究成功地使得模型能够获取到所需的训练样本。模型在经过优化训练后, 能够稳定地输出结果, 为后续的皮带位移故障诊断提供了可靠的基础。在完成皮带位移检测后, 研究将数据处理准确率和查全率等作为验证指标用于性能测试, 其中准确率可用公式 (16) 计算:

$$\text{Accuracy} = \frac{(TP + TN)}{(TP + TN + FP + FN)} \quad (16)$$

式中, TP 表示被模型预测为正类的正样本数量, TN 表示被模型预测为负类的负样本数量, FP 表示被模型预测为正类的负样本数量, FN 表示被模型预测为负类的正样本数量。查全率可用公式 (17) 计算:

$$\text{Recall} = \frac{TP}{(TP + FN)} \quad (17)$$

通过上述相关指标的计算能够在一定程度上印证故障诊断模型的具体性能。最后, 在构建带式输送机位移故障诊断过程时, 首先进行数据采集, 通过在托辊上安装传感器监测其状态。数据经无线网络传输至中心处理单元。在预处理阶段, 执行去噪、数字化和同步化, 以保证数据质量。随后, 从处理后的数据中提取关键特征, 如振动频率和幅度。利用这些特征, 构建并训练故障诊断模型, 采用改进的 DDNet 网络, 以识别故障类型。模型训练后, 通过验证和测试阶段, 使用故障案例数据集评估其准确性和鲁棒性。在实际部署中, 模型分析实时数据, 识别故障, 并通知操作员或控制系统。为维持模型的有效性, 定期更新模型, 整合新数据和故障案例。整个过程需确保逻辑性、准确性和技术严谨性, 实现高效的故障诊断。

4 皮带输送机位移故障诊断模型性能分析

4.1 故障诊断模型图像信息处理性能分析

为了确保实验能够有序进行, 研究对仿真环境和实验参数进行了设定。具体的实验配置为: 操作系统 Win10、CPU 型号 Intel Core i7-10700K, 3.8 GHz、显卡 RTX3080。在模型训练过程中具体的参数为: 迭代次数定为 300 次, 以确保模型充分学习; 初始学习率设为 0.01, 并设置了 0.001 的学习衰减率, 以适应训练过程中的变化; 权重衰减系数设为 0.005, 以防止模型过拟合。所有图片都统一处理为 $1\ 024 \times 768$ 的像素尺寸, 数据样本数量确定为 10 个。同时为了充分验证故障诊断模型在带式输送机皮带位移图像上的检测性能, 研究利用收集到的带式输送机图像来构建数据集。收集图像的标准包括清晰度、多样性、无背景干扰和分辨率。即收集到的图像清晰度和分辨率必须满足 $1\ 024 \times 768$ 的像素要求, 同时收集的图像需要来自不同的工作时间段, 以此提升模型的泛化能力, 并且没有干扰因素对图像产生影响, 确保模型对图像信息处理时能够专注于图像特征的分析。研究一共收集了 1 280 张符合研究标准的带式输送机的皮带图片, 其中包含了 650 张无煤炭传输的图片和 630 张有煤炭传输的图片, 研究利用这些图片构建了一个数据集。研究了验证故障诊断模型的性能, 将 K 最近邻算法 (KNN, K-nearest neighbor)、实时目标检测算法 (YOLOv4, you only look once version 4) 作为对比方法与故

障诊断模型进行性能对比。性能验证指标包括数据收敛情况、数据处理准确率、图像处理精密度、查全率。收集的数据包括物料放置、皮带状况、张力水平、滚筒安装和装置调整等参数。准确率数据的依据是基于故障模拟实验的结果。研究进行了 100 次独立实验，每次实验均记录了模型的预测结果，并与实际发生的位移情况进行对比，最终的准确率是这 100 次实验的平均值。3 种方法在图像信息处理过程中的数据收敛性能和数据处理准确率对比结果如图 6 所示。




图 6 3 种方法收敛情况与数据处理准确率对比结果

由图 6 (a) 对比分析可知，随着迭代次数的递增，3 种不同方法所展现出的收敛值呈现出明显的下降趋势。其中检测模型的收敛曲线最平稳，从迭代开始到结束，其收敛值的下降都保持在一个相对稳定的速率。尤其在迭代次数达到 83 次时，其收敛曲线趋于平稳，这说明检测模型在这个点上已经达到了相对稳定的收敛状态。相较于检测模型，YOLOv4 算法在迭代至 116 次时，其收敛曲线才趋于稳定，而 KNN 更是需要迭代至 189 次，其收敛才显得相对平稳。由此可见，检测模型在收敛速度上具有明显的优势，比 YOLOv4 算法快了 33 次，比 KNN 更是快了 106 次之多。收敛速度差异表明在实际应用中检测模型能够更快地达到稳定状态，从而提高图像数据处理的效率。由图 6 (b) 对比可知，3 种方法在皮带边缘图像数据处理过程中的准确率存在明显的差异。其中检测模型在皮带边缘图像数据处理上的处理能力明显优于对比方法，其检测准确率平均值为 95.27%。YOLOv4 算法和 KNN 在皮带边缘图像数据处理过程中的检测准确率平均值分别为 89.93% 和 85.06%。检测模型的图像数据处理准确率比 YOLOv4 算法和 KNN 的准确率高出了 5.34% 和 10.21%。这说明研究构建的检测模型在图像数据信息处理过程中的优越性能。检测模型不仅能够更准确地识别出皮带边缘，还能在一定程度上提高整个图像处理流程的稳定性和可靠性。

为了进一步验证检测模型在输送机皮带位移图像数据检测中的性能，研究将图像数据处理精密度、查全率作为验证指标，用于性能验证。3 种方法在图像数据处理中的精密度和查全率对比结果如图 7 所示。由图 7 (a) 对比可知，3 种方法的精密度随着迭代次数的增加，都存在一定的波动，且随着迭代次数的增加检测精密度都有一定的上升。其中检测模型在皮带边缘图像数据处理过程中的精密度平均值为 95.37%。YOLOv4 算法和 KNN 在皮带边缘图像数




图 7 3 种方法在图像数据处理中的精密度和查全率对比结果

据处理过程中的精密度平均值分别为 90.51% 和 88.29%。检测模型的图像数据处理精密度比 YOLOv4 算法和 KNN 的精密度高出了 4.86% 和 7.08%。由图 7 (b) 可知，随着迭代次数的增加，3 种方法的图像数据查全率也具有一定的波动性。其中检测模型的图像数据查全率平均值为 93.46%，YOLOv4 算法和 KNN 的皮带边缘图像数据查全率平均值分别为 89.37% 和 86.28%。检测模型的图像数据查全率比 YOLOv4 算法和 KNN 的查全率高出了 4.09% 和 7.18%。由此说明无论是在图像数据处理精密度还是查全率方面，检测模型的性能都显著优于 YOLOv4 算法和 KNN。这也验证了检测模型在图像数据信息处理过程中的高准确性和稳定性，为输送机皮带位移的精确检测提供有力的技术支持。为了验证用于构建故障诊断模型方法的性能，研究进行了消融实验。消融实验将 Canny 算子、DN-Net 网络与改进 DNNet 网络进行对比，对比指标为图像数据处理的 F_1 值。




图 8 3 种方法在图像处理中的 F_1 值对比结果

3 种方法在图像数据处理中的 F_1 值对比结果如图 8 所示。传统的 Canny 算子在图像数据处理中的 F_1 值为 0.826，相对较低。这可能是因为 Canny 算子在处理复杂图像时，难以准确地检测到所有的故障特征，尤其是在噪声较多或图像质量较差的情况下。DNNet 网络虽然也表现不错，但其 F_1 值仅为 0.873，略低于改进 DNNet 网络。这说明在图像数据处理中，对原始网络进行改进和优化，能够有效提升模型的性能。而改进 DNNet 网络在图像处理中取得了 0.915 的 F_1 值，这一成绩显著优于其他两种方法。改进 DNNet 网络可能通过引入新的网络结构、优化算法或者增加数据增强策略等手段，使得其在处理图像数据时能够更

准确地捕捉故障特征,从而提高了检测精度。这说明改进 DNNet 网络在图像数据处理中确实表现出了更高的性能。

4.2 故障诊断模型应用性能分析

为了验证故障诊断模型的应用性能,研究对带式输送机皮带图像数据进行了位移测试。在测试过程中,设定了位移阈值,当检测到的位移阈值大于 75% 时属于严重位移,意味着皮带可能发生了严重的故障或损坏,需要立即停机检修。当阈值大于 60% 小于 75% 时属于中度位移,虽然尚未达到紧急停机的程度,但也需要密切关注并采取相应的预防措施。当位移量在 50~60% 之间时,为轻度位移,可能仅是轻微的偏差或波动,但仍需记录并分析。当阈值小于 50% 时皮带属于正常工作范围,无需过多干预。

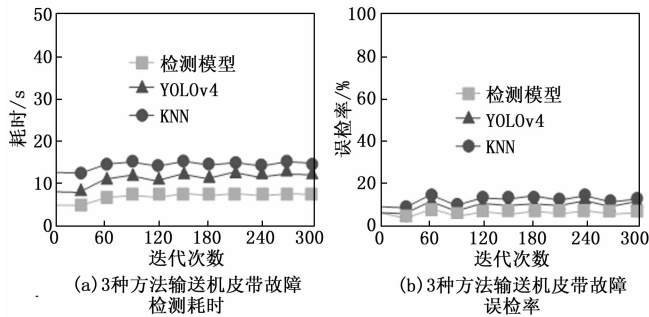


图 9 3 种方法对故障诊断耗时和故障误检率对比结果

3 种方法在带式输送机故障诊断中的检测耗时与故障误检率对比结果如图 9 所示。由图 9 (a) 可知,随着迭代次数的增加,故障诊断耗时总体呈上升趋势,其中故障诊断耗时最低的是检测模型,平均耗时为 6.8 s。YOLOv4 算法和 KNN 在带式输送机皮带故障诊断中的平均耗时分别为 11.3 s 和 14.9 s。检测模型在带式输送机皮带故障诊断中的平均耗时比 YOLOv4 算法和 KNN 的平均耗时缩短了 4.5 s 和 8.1 s。这说明检测模型在故障诊断过程中能够更快地给出结果,从而提高了故障诊断的实时性和效率。由图 9 (b) 可知,在带式输送机皮带位移故障诊断中,故障的误检率也有一定的差异。检测模型的故障误检率平均值为 3.62%,YOLOv4 算法和 KNN 在带式输送机皮带故障诊断中的误检率平均值分别为 8.61% 和 10.22%。故障诊断模型在带式输送机皮带故障诊断中的误检率平均值比 YOLOv4 算法和 KNN 的误检率平均值减小了 4.99% 和 6.6%。这说明检测模型在识别故障时具有更高的准确性,能够更可靠地判断故障情况。在带式输送机皮带位移故障诊断中,误检率是一个极其重要的指标。过高的误检率不仅会导致维修成本的增加,还可能对生产线的正常运行造成干扰。由此可知,检测模型在带式输送机故障诊断中具有更优异的性能,较低的检测耗时和故障误检率在实际应用中能够快速、更准确地识别故障发生情况。为了验证故障诊断模型的实际应用效果,研究将带式输送机进行区域划分,分为横向区域和纵向区域,通过这种细致的区域划分,研究人员能够更精确地评估模型在不同工作区域内的性能。并将检测模型预测值与真实值进行对比,研究选择的对比指标包括识

别准确率、识别数据召回率、识别精度平均值和检测速率。检测模型预测值与真实值的对比结果如表 1 所示。

表 1 检测模型预测值与真实值的对比结果

方法	检测对象	检测指标			
		识别准确率/%	识别数据召回率/%	精度平均值/%	检测速率/(帧·s ⁻¹)
检测模型预测值	横向区域	93.68	89.05	90.64	30.5
	纵向区域	94.05	90.25	90.17	31.2
真实值	横向区域	95.01	93.18	93.05	35.6
	纵向区域	95.96	93.65	93.11	35.1

由表 1 可知,在识别准确率对比中,模型在横向区域的预测值为 93.68%,与真实值 95.01% 相比,虽然存在 1.33% 的差距,但这一差距相对较小,显示出模型在横向区域故障识别上的高准确性。在纵向区域,模型预测值 94.05% 与真实值 95.96% 的差距为 1.91%,这也能表明模型在纵向区域也具有相当高的识别准确率。由此说明模型在大多数情况下都能准确地识别出带式输送机的故障情况,证明了其高度的可靠性。在召回率对比中,横向区域,模型的预测值为 89.05%,而真实值为 93.18%,两者相差 4.13%。在纵向区域,模型预测值为 90.25%,真实值为 93.65%,预测值与真实值之间的差距为 3.4%。在横向区域与纵向区域的对比中,预测值与真实值的差距均小于 4.5%,这也体现了该模型在数据召回率中具有较高的可靠性。在精度的对比中,横向区域中,模型精度预测值为 90.64%,真实值为 93.05%,相差 2.41%。在纵向区域,模型预测值为 90.17%,而真实值为 93.11%,二者相差 2.94%。这说明模型在大多数情况下都能提供较为准确的预测结果,验证了模型具有较高的适应性和稳定性。在皮带位移故障诊断速率对比中,在横向区域,模型检测速率为 30.5 帧·s⁻¹,真实值为 35.6 帧·s⁻¹,二者相差 5.1 帧·s⁻¹。在纵向区域,模型检测速率为 31.2 帧·s⁻¹,真实值为 35.1 帧·s⁻¹,二者相差 3.9 帧·s⁻¹。从检测速率的角度而言,模型在横向区域和纵向区域的检测速率均略低于真实值,但从整体的检测效率和性能来看,检测模型的检测速率处于较高的检测效率水平,能够及时发现皮带发生位移的情况。综上所述,虽然检测模型在带式输送机故障诊断中与真实值存在一定的差距,但整体上仍具有较高的适用性和可行性。为了增强实验部分的深度与广度,研究通过改变物料在皮带上的分布模式,模拟了物料放置不当的情况。实验共进行了 20 次,每次运行时长为 2 小时。调整皮带两端的张力,模拟张力不平衡情况。选取不同使用年限的皮带样本,通过加速老化实验模拟皮带变形老化过程。在物料放置不当的实验中,模型识别准确率为 92%。皮带老化与变形测试中,模型准确识别老化皮带的位移故障,准确率为 88%。张力不平衡实验显示,随着张力差的增加,模型的识别准确率最高达到 90%。证明了研究方法在不同故障条件下都具有良好的诊断能力。

5 结束语

在煤矿带式输送机皮带位移故障诊断中, 由于传统故障诊断方法大多依赖于人工巡检和经验判断, 存在检测效率低下、误判率高等问题。为了解决这些问题, 研究提出了一种结合边缘检测算法与改进 DDNet 网络的故障诊断模型。通过仿真实验的性能验证表明, 在图像数据处理过程中, 检测模型对图形进行数据处理的平均耗时为 6.8 s, 比 YOLOv4 算法和 KNN 的平均耗时缩短了 4.5 s 和 8.1 s。在故障误检率对比中, 故障诊断模型的误检平均值为 3.62%, 比 YOLOv4 算法和 KNN 的误检率平均值减小了 4.99% 和 6.6%。同时在皮带横向区域检测中, 检测模型预测值与真实值的识别准确率、识别数据召回率、检测精度和检测速率分别相差 1.33%、4.13%、2.41% 和 5.1 帧 · s⁻¹。这说明研究提出的结合边缘检测算法与改进 DDNet 网络的煤矿带式输送机多源异构数据皮带位移故障诊断模型在理论和实践方面都取得了显著的成果。即使在某些数据源出现故障或数据质量较差的情况下, 模型仍能依靠其他数据源的信息进行准确的故障识别。虽然研究在煤矿带式输送机皮带位移故障诊断中取得了显著效果, 但仍然存在一定的不足之处, 比如在光照条件极差或存在大量噪声干扰的情况下, 模型的检测效果可能会受到一定影响。因此, 下一步研究可以探索如何增强模型的鲁棒性, 以适应更多样化的工作环境。

参考文献:

- [1] 方崇全. 煤矿带式输送机巡检机器人关键技术研究 [J]. 煤炭科学技术, 2022, 50 (5): 263-270.
- [2] 王海军, 王洪磊. 带式输送机智能化关键技术现状与展望 [J]. 煤炭科学技术, 2022, 50 (12): 225-239.
- [3] KRISTIAN F P, MULYONO J, SANTOSA H. Preventive maintenance scheduling on belt conveyor using failure mode effect and criticality analysis [J]. Jurnal System Teknik Industry, 2021, 23 (1): 111-120.
- [4] 孙亮, 周公博, 王惟, 等. 用于带式输送机自检托辊的能量收集器设计 [J]. 工矿自动化, 2021, 47 (7): 50-56.
- [5] ALHARBI F, LUO S, ZHANG H, et al. A brief review of acoustic and vibration signal-based fault detection for belt conveyor idlers using machine learning models [J]. Sensors, 2023, 23 (4): 1902-1935.
- [6] JIE H, LI S, SAMUEL A, et al. Squeeze-and-excitation networks [C] // Proceedings of the 2018 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE, 2020: 2011-2023.
- [7] HOU Q B, ZHOU D Q, FENG J S. Coordinate attention for efficient mobile network design [C] // Proceedings of 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Nashville, IEEE, 2021: 13708-13717.
- [8] 朱宏禹, 韩建宁, 徐勇. 基于改进型 YOLOv5s 的印刷线路板瑕疵检测 [J]. 国外电子测量技术, 2023, 42 (3): 152-159.

- [9] 刘锋, 白金牛. 基于视觉技术的带式输送机跑偏检测方法 [J]. 山西焦煤科技, 2023, 47 (4): 25-28.
- [10] LIU Y, MIAO C, LI X, et al. Research on deviation detection of belt conveyor based on inspection robot and deep learning [J]. Complexity, 2021, 21 (6): 1-15.
- [11] 谭恒, 张红娟, 靳宝全, 等. 基于机器视觉的煤矿带式输送机跑偏检测方法 [J]. 煤炭技术, 2021, 40 (5): 152-156.
- [12] CHUDASAMA P, DARJI J, DALVI Y. Design, analysis and optimisation of belt conveyor for coal application [J]. Int J Eng Res Technol, 2021, 9 (3): 669-671.
- [13] 田博, 段兰兰, 王虎军, 等. 基于 ANFIS-PID 的大运距矿石输送控制系统设计 [J]. 自动化仪表, 2023, 44 (4): 65-71.
- [14] 田立勇, 唐瑞, 于宁, 等. 带式输送机更换托辊用皮带举升机构设计与应用 [J]. 工程设计学报, 2023, 30 (6): 667-677.
- [15] 董跃华, 张先光. 二值形态学边缘检测算法的量子实现及仿真 [J]. 量子电子学报, 2023, 40 (5): 654-665.
- [16] 于新善, 孟祥印, 金腾飞, 等. 基于改进 Canny 算法的物体边缘检测算法 [J]. 激光与光电子学进展, 2023, 60 (22): 213-222.
- [17] 赵云龙. 煤矿主斜井带式输送机智能巡检系统设计 [J]. 煤炭技术, 2022, 41 (10): 219-222.
- [18] ZHANG J, KONG X, LI X Y. Fault diagnosis of bearings based on deep separable convolutional neural network and spatial dropout [J]. Chinese Journal of Aeronautics, 2022, 35 (10): 301-312.
- [19] 刘建思, 尹丽菊, 潘金凤, 等. 基于参数化对数图像处理模型的光照不均匀图像的边缘检测算法 [J]. 激光与光电子学进展, 2021, 58 (22): 132-141.
- [20] 刘阳, 栗航, 何倩, 等. 基于云-边协同变分自编码神经网络的设备故障诊断方法 [J]. 计算机工程与科学, 2023, 45 (7): 1188-1196.
- [21] 毕东月. 基于深度学习的输煤皮带故障视觉检测方法研究 [J]. 中国安全生产科学技术, 2021, 17 (8): 84-90.
- [22] 田立勇, 唐瑞, 于宁, 等. 带式输送机更换托辊用皮带举升机构设计与应用 [J]. 工程设计学报, 2023, 30 (6): 667-677.
- [23] 曹建文. 皮带运输机轻载模式运行效率优化控制 [J]. 自动化仪表, 2022, 43 (7): 28-31.
- [24] REZATOFIGHI H, TSOI N, GWAK J Y, et al. Generalized intersection over union: a metric and a loss for bounding box regression [C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019: 658-666.
- [25] 杨文涛, 张维光. 基于改进 YOLOv5m 的弱小目标识别方法 [J]. 计算机测量与控制, 2022, 30 (12): 218-223.
- [26] 沈希忠, 吴迪. 基于 YOLO 的铝型材料表面小缺陷检测 [J]. 浙江工业大学学报, 2022, 50 (4): 372-380.
- [27] SELVARAJU R R, COGSWELL M, DAS A, et al. GradCam: visual explanations from deep networks via gradient-based localization [C] // Proceedings of the IEEE International Conference on Computer Vision, 2017: 618-626.

(上接第 46 页)