

绞线插针绕制的断丝故障检测

杨 兰¹, 陈湘萍¹, 向伟明², 刘 章², 田登卫², 王民慧¹

(1. 贵州大学 电气工程学院, 贵州 贵阳 550025; 2. 遵义市飞宇电子有限公司, 贵州 遵义 563000)

摘要: 绞线插针作为微矩形连接器的关键结构, 在其绕制工艺过程中面临着一个挑战, 视觉上难以直观地区分金属线束是否断丝。为此, 提出一种融合卷积神经网络与 vision transformer (ViT) 的跨层模型, 整合深浅层网络以提取更为全面的绕线图像特征; 利用注意力机制, 进一步增强特征融合, 提升了模型对微小差异的感知力; 随后采取基于 Arcface 细粒度分类算法, 引入角边距来优化余弦角, 大幅增加了金属线束的类间差异性与相同特征的紧凑型。实验结果表明, 本模型以 91.9% 的高准确率识别出不同规格金属线束的断丝情况, 高效地解决了绞线插针绕制过程中的断丝识别难题, 为微矩形连接器的生产质量监控提供了一种高效可靠的技术方案。

关键词: 绞线插针; 断丝检测; 卷积神经网络; transformer; arcface

中图分类号: TP277

文献标志码: A

文章编号: 1003-7241(2025)12-0040-04

Detection of wire breakage faults in twist pin winding

YANG Lan¹, CHEN Xiangping¹, XIANG Weiming², LIU Zhang², TIAN Dengwei², WANG Minhui¹

(1. Department of College of Electrical Engineering, Guizhou University, Guiyang 550025, China;

2. Zunyi Feiyu Electronics Co., Ltd., Zunyi 563000, China)

Abstract: As the core structure of micro rectangular connectors, the twist pin faces a challenge in the winding process, it is difficult to visually identify whether the winding metal bundle is broken. To address this, the paper introduces a cross-layer model that merges convolutional neural networks with vision transformer, integrating both deep and shallow networks to extract a more comprehensive set of winding image features. By incorporating the attention mechanism, feature fusion is further enhanced, increasing the model's sensitivity to minute differences. Utilizing the fine-grained classification technology based on Arcface, which introduces an angular margin to optimize the cosine angle, significantly increases the inter-class distinction and compactness of identical features within metal wire bundles. Experimental results demonstrate that this model achieves a 91.9% high accuracy rate in identifying wire breakages of different specifications, efficiently solving the challenge of line break detection in the winding process of the twist pin. It provides an effective and reliable technological solution for the quality control of micro rectangular connector production.

Keywords: twist pin; line breaking detection; convolutional neural network; transformer; arcface

0 引言

微矩形连接器是航天军工领域的关键部件, 其中以弹性插头和刚性插孔构成的绞线插针结构, 显著增强了连接器在振动环境中的稳定与可靠。众多研究致力于提高绞线插针的生产质量, 涉及电连接器从绕制、铣削^[1]、装接^[2]和灌封^[3]等多个生产阶段, 到机械^[4]、电气^[5]和环境^[6]的性能分析, 以及故障检测系统^[7-8]研究。其中, 绞线插针在绕制流程中的质量直接影响插针的整体性能, 而相关方面的研究尚且不足。高效的绕线工艺需在一致张力下进行规则绞合, 增加了质量控制的复杂度。传统检测是人工观察工业镜头放大后的金属线束图像, 易受环境干扰, 长时间操作还容易导致观察者疲劳, 进而影响检测的准确性。

绞线插针通常用直径 0.04~0.18 mm 的紫铜或纯铜金属丝绕制, 构成微型(1.27 mm)、纳型(0.635 mm)或其

他规格的连接器的^[9], 然而金属丝的细微使得绕制过程中的断丝识别变得困难。针对类间高度相似和类内差异较小的问题, 刘清^[10]提出一套基于定向成对混合的细粒度图像数据增广算法, 实现更精细的细粒度图像分类; 然而何志祥等^[11]则通过 ResNet50 的深浅层网络关注通道相关性, 结合跨层协同注意力模块, 提升了多尺度信息融合的能力。这些研究凸显了深度学习在细粒度图像处理方面的显著成效。本文提出的改进 CNN-Transformer 跨层融合的断丝检测算法, 能够有效识别绞线插针绕制过程中的金属线束断裂情况, 从而大幅提高了绕线检测的精确度。

1 断丝检测融合模型

1.1 模型架构

本文提出的模型整体架构如图 1 所示。

图 1 中卷积神经网络 (convolutional neural network, CNN) 和 ViT 采取双向桥接的融合方式, ResNet 作为 CNN 模块, 其出色的局部特征提取能力对本文绕线图像间细微差别的识别尤为关键; 同时, ResNet 的残差结构可以有效

* 基金项目: 遵义市飞宇电子有限公司项目 (H2021490)

收稿日期: 2024-03-10

地防止深度模型中的梯度消失问题,确保深层特征的有效学习。ViT 模块通过将图像分割为小块来提取图像的全局内容,与 CNN 模块的跨层连接共同实现了局部与全局信息的综合特征编码,显著提升了模型的检测性能。通过转换为固定长度的向量,这些特征在 Transformer 编码器的自注意力机制中进行了深入的特征融合分析。考虑到插针绕线图像中断丝与未断丝之间类内差异较微,本文进一步采用 Arcface 损失函数优化模型,以此来提高分类的准确度。

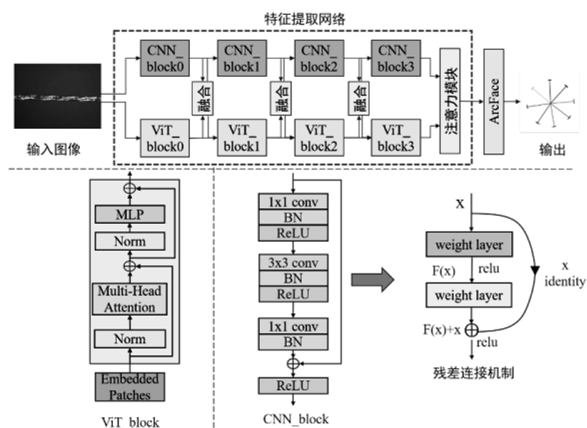


图 1 融合模型结构

CNN 模块采用的残差连接机制,可通过公式 $H(x) = F(x) + x$ 表示,其中残差块包含两条路径 $F(x)$ 和 x ,路径 $F(x)$ 是拟合残差,而 x 路径则代表恒等映射。残差块通过跨层方式直接连接使输入信息迅速地向前传播,有效地促进了信息流动,减少训练过程中的信息损失。

1.2 注意力机制

Transformer 是专为序列数据设计的深度学习架构,包括编码器和解码器两部分。ViT 只采用了编码器部分,结构简单且易于扩展。编码器部分是由归一化层 (Layer Normalization, LN)、多头注意力机制 (multi-head attention, MHA)、残差连接 (residual connection, RC) 和多层感知机 (multi-layer perception, MLP) 构成,核心在于多头注意力,使得模型能够并行捕捉序列中多位置信息,组成其的自注意力机制结构计算过程如图 2 所示。




图 2 自注意力模块计算过程

其中,Query、Key 和 Value 向量经过一个注意力机制转化为输出向量。输入的 Query 和 Key 向量具有 d_k 的维度,而 Value 向量的维度为 d_v 。在训练阶段,Query、Key

和 Value 向量组成 Q 、 K 和 V 矩阵,通过对相同的输入 X 进行线性变换,实现了自注意力机制的构建。自注意力机制计算如式 (1) 和式 (2) 所示。

$$\text{Attention}(Q, K, V) = \text{Softmax}\left(\frac{QK^T}{d_k}\right) \quad (1)$$

$$\begin{cases} Q = N^Q \odot X_q \\ K = N^K \odot X_k \\ V = N^V \odot X_v \end{cases} \quad (2)$$

注意力模块将 Query、Key 和 Value 参数分成 N 份,每一份由一个独立的注意力头处理。整合所有注意力头的计算结果,得到最终的注意力分数,使得模型能够精准地捕捉每个词间的复杂联系和细微差别。如式 (3) 所示,其中 Concat 表示拼接操作, W^0 表示线性矩阵, h_x 表示注意力头。

$$\text{MultiHead}(Q, K, V) = \text{Concat}(h_0, \dots, h_x) W^0 \quad (3)$$

1.3 ArcFace 损失函数

ArcFace 损失函数 (additive angular margin loss, AAM-Loss) [12] 为提升深度学习模型的特征识别能力提供了一种高效方法。在 Softmax 损失函数中加入一个角度边界,旨在让同类别的样本在特征空间中更紧密聚合,同时扩大不同类别样本间的距离。这种方法不仅增强了类内紧密度和类间区分度,而且提高了模型的识别准确性和泛化能力。式 (4) 是 Softmax 损失函数的计算表达式为

$$L_{\text{soft}} = -\frac{1}{N} \sum_{i=1}^N \log \frac{e^{w_i^T x_i + b_{y_i}}}{\sum_{j=1}^n e^{w_j^T x_i + b_j}} \quad (4)$$

其中, x_i 表示第 i^{th} 个图像特征, y_i 为第 i^{th} 个图像对应的实际类别标签, w_i 是与类别相关的权重参数;而 b_j 为类别的偏差项, N 和 n 分别表示训练样本的总数和类别的总数。通过对 softmax 损失函数进行改良,将偏差项 b_j 设为 0,引入权重 W 和特征向量 x 之间的角度信息 θ ,使 $W_j^T x_i = \|W_j\| \|x_i\| \cos \theta_j$ 。而 ArcFace loss 在此基础上引入角度间隔参数 m 来控制角度余弦值,即 $\cos(\theta + m) < \cos(\theta)$ ($\theta \in [0, \pi - m]$),让网络学习到更有区分度的特征,其表达式为

$$L = -\frac{1}{N} \sum_{i=1}^N \log \frac{e^{s(\cos(\theta_{y_i} + m))}}{e^{s(\cos(\theta_{y_i} + m))} + \sum_{j=1, j \neq y_i}^n e^{s(\cos \theta_j)}} \quad (5)$$

2 数据采集系统与数据集构建

2.1 数据采集系统

本文构建的绕线图像采集系统由可调节相机支架、USB 电子显微摄像头、绕线装置、照明系统和电脑组成。支架固定 USB 摄像头,照明系统选用环形光源可提供 360°全方位照明,USB 工业相机通过 USB 接口连接至 PC 端获取图像信息。采用型号为 XW500U3 的 USB3.0 数字

相机,选用的显微镜镜头,物镜的放大倍数在 0.7x 到 4.5x 之间,目镜的放大倍数为 0.5x。

2.2 数据集构建

利用数据采集系统对 3 线、6 线、9 线绕线规格进行数据采集,包括了断丝单根和不断丝的多角度图像(图 3)。为保障数据集的一致性,严格遵循了若干采集原则:保持摄像头与绕线的相对位置稳定、确保绕线两端受力均匀、维持显微镜的放大倍数不变,以避免由于受力不均而导致的形变。




图 3 数据集样本

最终构建了六种不同的绕线图像数据集(d3、d6、d9、m3、m6、m9),其中“d”表示断丝单根情况,“m”表示不断丝情况,后跟的数字 3、6、9 分别代表绕线规格。每个类别各有 500 张图像,总计达到 3 000 张,数据集以 7:3 的比例划分为训练集和验证集。随后,每张图像被重置为 224×224 像素大小,并进行了标准化处理(均值和方差均设为 0.5),再对训练集进行数据增强,包括随机裁剪至 190×190 像素,以 50% 的概率对图像进行水平翻转和垂直翻转,从而增强整个数据集的多样性和鲁棒性。

3 实验与分析

3.1 实验环境

本实验在 Windows 10 下进行,计算机处理器为 i7-10750H,GPU 为 GeForce GTX 3090,编程语言选用 Python 3.9.18,算法的实现建立在 PyTorch 深度学习框架,使用了 CUDA Toolkit 以充分利用 GPU 的并行计算能力。训练迭代 100 次,初始学习率为 0.001。实验的流程图如图 4 所示,进行数据增强后的训练集用于训练,随后测试集对

训练好的模型进行测试。

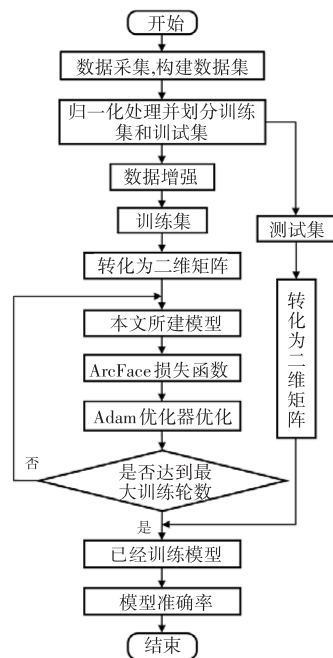


图 4 实验流程图

3.2 实验结果和讨论

3.2.1 模型对比实验

为了验证本文提出的模型在处理绕线检测任务时的性能,进行了对比实验。选择了两种具有代表性的特征提取网络进行比较。MobileNetV1 和 SqueezeNet。实验结果见表 1,表中展示了各模型在测试数据集上的准确率、精度、 F_1 分数、召回率的关键指标。

表 1 不同模型的性能比较

模型	Acc	F1	Precision	Recall
Our	0.919	0.911	0.918	0.912
MobileNetV1	0.904	0.902	0.910	0.910
SqueezeNet	0.884	0.892	0.895	0.891

结果表明,在识别具有微小差异的绕线图像任务上,本文的模型通过跨层融合 CNN 和 ViT 的策略,引入注意力模块和 Arcface 算法来提升特征识别的细粒度,对细微差异的捕捉与识别能力高于另外两种模型,证实了所提架构的高效性。SqueezeNet 通过 Fire 模块优化了特征流,增加了特征图的丰富性; MobileNetV1 则依赖深度卷积和逐点卷积有效地提取特征图中的通道信息,两者都减少了网络的参数数量,其中 MobileNetV1 展示了更高的计算效率。

混淆矩阵(confusion matrix, CM)是评价分类模型性能的关键工具,它可以直观地展示模型预测结果与真实标签之间的匹配程度。利用混淆矩阵对本文提出的模型进行评估,图 5 清晰显示了在 300 个验证样本上的性能。尤其是在 3 线正常图像的识别上,模型表现出了最高的准确率,而且未断丝图像的识别准确率也明显高于断丝图像,但断丝平均识别率也达到 91.3%,证明了该模型在特征提取和分类准确性方面的优异能力。

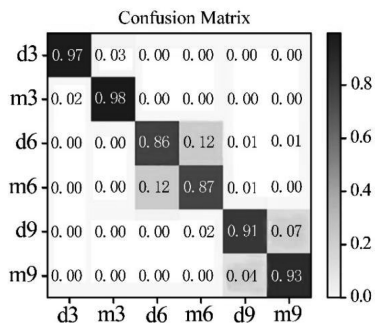


图5 验证集混淆矩阵

3.2.2 消融实验

为了深入探究模型各个组成部分对最终模型性能的贡献,进行消融实验,分步验证 ViT 模块、注意力模块以及 Arcface 模块对模型整体性能的影响,实验结果见表 2。

表 2 消融实验

方法	Acc	F_1	Precision	Recall
Resnet	0.874	0.862	0.876	0.852
+ViT	0.899	0.874	0.881	0.871
+注意力机制	0.910	0.892	0.898	0.903
+Arcface	0.919	0.911	0.912	0.910

根据表 2 中的实验数据,可以观察到模型的多个性能指标逐渐上升。通过将 Resnet 与 ViT 跨层融合,模型精度提升了 2.5%,这归因于局部和全局特征融合策略的有效优化。注意力和 Arcface 引入之后模型精度再次提升了 2%,最终模型精度达到 91.9%。这不仅证明了本文模型在处理绕线图像分类任务上的高效性,也凸显了融合浅层细节与深层语义特征的优势,以及利用自注意力机制和 Arcface 算法对于增强模型的理解与处理能力的关键作用。

3.2.3 Arcface 模块特征分布可视化

为直观地证明 Arcface 损失函数所带来的效益,图 6 和图 7 展示了其对训练数据特征二维分布的可视化。未引入 Arcface loss 之前(图 6),模型对不同类别的特征辨识度较低,各类特征相互混淆,区分度不明显。而引入 Arcface loss 后(图 7),可以明显观察到不同类别之间的间距增加,而同类别类内的聚合度提升,显著增强了模型在特征空间中对不同类别的分辨力。这种改进不仅优化了特征分布,也直接提升了模型的分类准确率和鲁棒性,从而验证了 Arcface loss 在提高模型区分度方面的有效性。




图 6 未加入 Arcface 的数据特征分布




图 7 加入 Arcface 的数据特征分布

4 结束语

本文提出了一种融合 CNN 和 ViT 的并行化模型,通过注意力机制模块极大提升了对细微差异的识别能力。同时,引入基于 Arcface 的细粒度分类技术,有效地扩大了图像的类间距离并缩小类内距离,使得模型在绕线金属线束断丝检测任务上的准确率达到 91.9%。这项研究不仅显著优化了绕线故障检测流程,还为相关技术领域贡献了一种新的解决方法。

参考文献

- [1] 李娟, 赵友友, 刘寅傲, 等. 超微矩形电连接器 0.28 mm 弹性绞线插针腐蚀质量问题及工艺改进[J]. 质量与可靠性, 2023 (3):14-17.
- [2] 陈雨田, 陈峰, 杨鹏伟, 等. 航天产品电连接器压接工艺分析及改进[J]. 航天制造技术, 2022 (2):46-49, 76.
- [3] 张睿明, 施玮. AirBorn 微矩形电连接器绝缘防护工艺研究[J]. 中国设备工程, 2023 (22):75-77.
- [4] 张平均, 嵇凯生, 王颖, 等. 电连接器接触件接触特性仿真分析[J]. 福建工程学院学报, 2023, 21(3):264-268.
- [5] 丁睿, 倪俊芳, 黄世彬. 电连接器多物理场耦合接触电阻研究[J]. 电工电气, 2023 (7):21-26.
- [6] 周游, 侯婕, 薛亮, 等. 某型电子元器件海洋环境适应性评估方法研究[J]. 电子产品可靠性与环境试验, 2023, 41(4):29-35.
- [7] 赵威, 钱进, 王一桂, 等. 基于樽海鞘群算法的床温多变量系统辨识研究[J]. 自动化技术与应用, 2024, 43(2):1-5.
- [8] WU W, LI Q. Machine vision inspection of electrical connectors based on improved Yolo v3[J]. Ieee Access, 2020(8): 166184-166196.
- [9] 刘后伦. 绞线插针在微型连接器中的应用研究[J]. 机电元件, 2022, 42(5):38-40.
- [10] 管楠楠. 基于全局 CNN 与局部 LSTM 的国画图像分类算法[J]. 自动化技术与应用, 2024, 43(4):115-117.
- [11] 何志祥, 齐琦, 何伟, 等. 跨层协同注意和通道分组注意的细粒度图像分类[J]. 计算机系统应用, 2024, 33(3):126-133.
- [12] DENG J, GUO J, XUE N, et al. ArcFace: additive angular margin loss for deep face recognition [C]//2019 IEEE Conference on Computer Vision and Pattern Recognition. Long Beach: IEEE, 2019: 4685-4694.

作者简介: 杨 兰(1997—),女,硕士研究生,研究方向:嵌入式系统。

通信作者: 王民慧(1962—),女,副教授,研究方向:嵌入式系统。