

# 基于卷积神经网络的羊绒纤维长度检测模型及其应用

童俊毅<sup>1</sup>, 李效宇<sup>2</sup>, 苑宇豪<sup>1</sup>, 杨瑞华<sup>\*1</sup>

(1. 江南大学纺织科学与工程学院, 江苏无锡 214122; 2. 内蒙古中科融汇绒业发展有限公司, 内蒙古巴彦淖尔 015000)

**摘要:**针对传统羊绒纤维长度测量方法效率低、精度受人为因素影响的问题,采用卷积神经网络技术,对羊绒纤维在阈值化处理中的断裂修复和交叉区域检测进行系统研究;设计了基于U-Net框架的纤维补断模型和基于ResNet-50编码器的交叉点检测模型,通过引入跳跃连接机制和混合损失函数,解决因阈值处理导致的纤维断裂和类别不平衡的问题。研究表明,纤维补断模型的像素准确率达到98.72%,交叉点检测模型具有良好的分割精度和泛化能力;模型测得的纤维平均长度与手排法结果的标准差最低为0.28 mm,验证了该方法在羊绒纤维长度测量中具有较高的精度、稳定性和实用性。

**关键词:**羊绒;纤维长度检测;卷积神经网络;图像处理;深度学习

**中图分类号:**TS 131.9;TP 183 **文献标志码:**A **文章编号:**2096-1928(2025)06-0471-07

## Cashmere Fiber Length Measurement Model Based on Convolutional Neural Network and Its Application

TONG Junyi<sup>1</sup>, LI Xiaoyu<sup>2</sup>, YUAN Yuhao<sup>1</sup>, YANG Ruihua<sup>\*1</sup>

(1. College of Textile Science and Engineering, Jiangnan University, Wuxi 214122, China; 2. Inner Mongolia ZHONG KE RONG HUI Cashmere Industry Development Co., Ltd., Bayannur 015000, China)

**Abstract:** To address the issues of low efficiency and human factor-induced inaccuracies in traditional cashmere fiber length measurement methods, convolutional neural network technology was adopted to conduct a systematic study on fracture repair and cross-region detection during the thresholding process of cashmere fibers. A fiber fracture repair model based on the U-Net framework and a cross-point detection model based on the ResNet-50 encoder were designed. By incorporating skip connection mechanisms and hybrid loss functions, the problems of fiber continuity restoration and class imbalance were effectively resolved. The research demonstrates that the fiber fracture repair model achieved a pixel accuracy of 98.72%, and the cross-point detection model exhibited strong segmentation precision and generalization capability. The standard deviation between the average fiber length measured by the model and the results from the manual arrangement method was as low as 0.28 mm, verifying that this method offers high precision, stability, and practicality in cashmere fiber length measurement.

**Key words:** cashmere, fiber length measurement, convolutional neural network, image processing, deep learning

羊绒是一种轻薄柔软且保暖舒适性好的天然动物纤维<sup>[1]</sup>,因其价格昂贵,具有“软黄金”之称。中国的羊绒产量与质量一直位于世界前列,羊绒相关

产业是重要的民生经济。在羊绒纤维的品质评定中,纤维长度是一项重要的指标,其直接影响羊绒纱线及其制成品的性能<sup>[2-3]</sup>,同时也是评估羊绒纤

收稿日期:2025-01-10; 修订日期:2025-09-02。

基金项目:国家自然科学基金面上项目(52273034)。

作者简介:童俊毅(2002—),男,硕士研究生。

\* 通信作者:杨瑞华(1981—),女,教授,博士生导师。主要研究方向为新型纺纱方法。Email:yangrh@jiangnan.edu

维价格的重要依据。

目前,行业内普遍采用传统的手排法检测羊绒纤维长度,但这种方法耗时较长,测长结果易受检测人员操作熟练程度的影响,且难以控制误差<sup>[4]</sup>。因此,亟需推动羊绒自动化检测方法的研发与改进。在自动化检测方面,目前应用较广的方法为仪器检测法,主要包括电容法与光学法。电容法先通过梳理羊绒制成一端平齐的羊绒纤维束,利用 Almeter 型电容仪测量其电容变化,得到不同长度纤维的根数,再计算羊绒纤维的平均长度<sup>[5]</sup>;光学法通过 OFDA4000 型光学仪拍摄纤维束从根部到梢部的连续图像,经图像拼接与纤维提取后获取所有纤维的长度信息<sup>[6-7]</sup>。这两种检测方法均能输出近似根数加权的长度累计分布结果<sup>[8-9]</sup>。还有一种新型的检测方法——双须光电法,其原理是利用图像传感器测量须丛各点的透光强度,得到纤维长度与纤维相对根数的变化曲线,并计算平均长度、短绒率等指标<sup>[10]</sup>。仪器法相比手排法人为误差较低,检测效率高,但仪器的价格昂贵,且实际检测耗用的纤维量远超过手排法。

相机技术的快速发展和深度学习在图像处理领域的广泛应用,使得基于计算机视觉的纤维长度测量方法成为可能。利用数码相机捕获纤维图像,并结合图像处理技术简化手排法的操作流程,可以避免人为因素干扰,从而快速、客观地测量纤维长度<sup>[11]</sup>。然而,在实际应用中仍面临两个核心技术难题:① 纤维在阈值分割等图像处理操作中易发生断裂,影响长度测量精度;② 数码相机难以准确识别复杂的纤维交叉区域,任何单个交叉点的判断错误都可能导致整根纤维追踪失败。

当前,即便使用普通消费级相机也能捕获清晰的纤维图像,这为图像分析测量法的实施奠定了基础。利用图像处理技术,可以简化手排法的操作流程,避免人为因素造成的干扰,从而提高检测效率。基于此,文中提出一种融合深度学习与全局优化算法的羊绒纤维长度自动测量方法。该方法设计了基于 U-Net 框架的纤维补断模型和基于 ResNet-50 的交叉点检测模型,旨在解决断裂纤维修复和纤维交叉区域识别的技术难题,为羊绒纤维长度的高效测量提供可靠的技术方案。

## 1 纤维图像检测模型的设计

### 1.1 卷积神经网络结构

卷积神经网络(convolutional neural networks, CNN)是一种深度学习模型,擅长处理与图像相关

的各类任务,常用于学习位置和尺寸不变的结构<sup>[12]</sup>。CNN 通过卷积操作提取局部特征,并逐层叠加以获得全局语义信息,在图像分类、目标检测和语义分割等任务中被广泛应用<sup>[13-14]</sup>。

卷积神经网络的模块化结构和对特征提取的灵活性,使其在处理复杂图像任务时能够提供高效的解决方案。在 CNN 的基础上,研究者提出了多种改进的 CNN 架构,以满足不同的应用需求。其中, U-Net 和 ResNet 是两种经典的网络结构,分别在语义分割和深层特征提取方面具有突出表现<sup>[15-16]</sup>。文中针对纤维补断和纤维交叉检测的需求,分别采用基于 U-Net 框架和基于 ResNet-50 的训练模型,通过将两种网络的优势相结合,实现纤维图像的高精度处理。纤维测长流程为:① 对采集到的图像进行一系列预处理,并利用基于 U-Net 框架的纤维补断模型修复阈值化后断开的纤维;② 将修复后的二值图输入基于 ResNet-50 的纤维交叉判断模型,以识别并统计交叉部分的纤维像素;③ 将修复后的纤维像素与统计的交叉部分纤维像素相加,得到总纤维像素,通过计算得到样品的平均纤维长度。具体流程如图 1 所示。

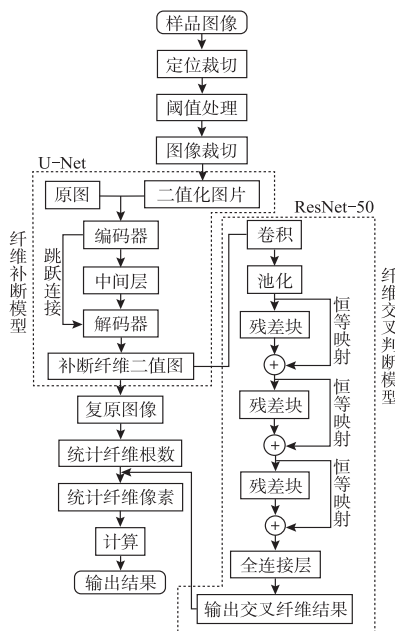


图 1 纤维测长流程


Fig. 1 Fiber length measurement process

### 1.2 纤维补断模型

纤维在进行阈值处理去除噪点的过程中,不可避免会丢失部分纤维本体。为了修复断裂纤维,确保纤维图像的完整性,文中设计了一种基于 U-Net 框架的纤维补断模型。U-Net 是一种对称的编码器-解码器结构,最早被用于医学图像的分割任务。它通过以下步骤实现高低分辨率特征融合:① 编码器

逐层提取输入图像的高维特征;② 解码器利用反卷积操作恢复特征图的空间分辨率;③ 编码器和解码器之间跳跃连接。该模型可以将图像的全局语义信息与局部细节特征有效结合,因此在处理纤维图像这类细节敏感的任务中具有明显优势<sup>[17]</sup>。

在此基础上,文中对U-Net框架进行了改进,以适应纤维补断任务的需求,具体框架结构如图2所示。该模型采用双通道输入结构:原始灰度图像提供纤维的形态与背景信息,二值化图像突出纤维的结构特征,以增强对断裂点的定位能力。这种多模态的输入方式能够为编码器部分提供更多的特征信息。在编码器中采用像素为 $3 \times 3$ 的卷积核,捕捉图像的局部细节特征;同时根据网络深度逐步增加卷积通道数,提升特征提取的多样性。在解码器中通过引入跳跃连接,将编码器中高分辨率的特征直接传递到解码器对应位置,从而有效恢复纤维边缘的细节,并减少特征丢失的问题。输出层采用Sigmoid激活函数,将特征图映射到 $[0,1]$ 区间,生成一张纤维补断后的概率图,用以表示每个像素属于纤维或背景的概率,并在后续处理中通过阈值操作,将概率图二值化为最终的纤维补断后图片。



注: ↓代表卷积; ←代表池化; →代表转置卷积; 红色数字代表通道数; 蓝色数字代表图像分辨率的像素数。

图2 U-Net 框架结构

Fig. 2 U-Net framework structure

### 1.3 纤维交叉检测模型

在纤维交叉点检测任务中,由于交叉点通常在

整张图像中的占比非常低,因此直接使用传统卷积神经网络可能面临正负样本不平衡问题,从而影响模型的检测精度。为了解决这一问题,文中基于ResNet-50 编码器的U-Net 框架对纤维交叉检测任务进行设计和改进。ResNet-50 作为深度残差网络,具有强大的特征提取能力,其引入的残差模块能够缓解深层网络的梯度消失问题,并有效增强对细粒度特征的捕捉能力。

在深度学习中,损失函数是评估模型预测结果与真实标签之间差异的核心指标,也是指导模型参数优化的关键。通常需要根据任务的差异选择适合的损失函数,以突出特定目标的优化方向。文中模型结合了两种常用的损失函数——Dice Loss 和 Focal Loss,以提升模型对交叉点区域的检测能力。Dice Loss 主要用于衡量模型在小区域(交叉点)上的分割性能,通过计算预测区域与真实区域的重叠程度,帮助模型更准确地关注这些目标区域;Focal Loss 通过提高模型难以识别样本的权重,降低简单样本(背景区域)对整体损失的影响,从而使模型更专注于交叉点的学习。为了进一步优化 Focal Loss,文中调整了类别权重,将交叉点的权重设置为 0.9,背景区域的权重设置为 0.1,从而增强了模型对交叉点的敏感性,以改善类别不平衡的问题。

## 2 模型训练与处理

### 2.1 材料

羊绒样品,内蒙古巴彦淖尔羊绒加工厂提供。经验丰富的检验员采用手排法测量羊绒纤维长度,以此作为参考标准。

### 2.2 实验环境

硬件配置:CPU 为 Intel Xeon Silver 4214R, GPU 为 NVIDIA RTX 3080 Ti;软件环境:Python 版本为 3.12,PyTorch 版本为 2.3.0,CUDA 版本为 12.1。所有训练均部署在 AutoDL 计算云上。

### 2.3 数据集与预处理

实验数据通过自行拍摄获取,样品制作流程为:① 准备 2 条长 10 cm、宽 1 cm 的黑色卡纸,其中一条贴上黑色双面胶,羊绒样品约 0.3 g;② 将羊绒样品一端用手捏住,另一端用钢梳梳理至纤维平直;③ 两端用手捏紧,使中间的纤维尽可能平直;④ 将伸直部分粘贴在双面胶上;⑤ 重复上述步骤,直至卡纸上的双面胶被纤维覆盖,并将另一条卡纸覆盖在双面胶上后压紧,使纤维固定在两条卡纸之间;⑥ 将样品在绒板上梳理整齐,确保两端无明显缠结后,用相机拍照获取原始图像。具体流程如图 3 所示。




图 3 样品制作流程

Fig. 3 Sample production process

预处理流程为:①对拍摄的原始图像进行灰度化处理,以减少数据量并提高处理效率;②利用代码自动定位黑绒板区域和纤维位置,对图像进行裁切,提取左端和右端纤维区域;③为适配模型,图像进一步裁切成像素为 $256 \times 256$ 的小块,不足部分以黑色像素填充;④通过阈值分割法去除噪点,仅保留纤维主体,最终生成用于模型训练的黑白二值图像。

## 2.4 模型训练

纤维补断与纤维交叉检测的模型训练分为两个阶段:第 1 阶段利用基于 U-Net 框架的卷积神经网络生成补断后的纤维二值图;第 2 阶段使用基于 ResNet-50 编码器的 U-Net 框架检测纤维交叉点。两个阶段模型的训练过程每次选取 4 个样本;学习率设置为 0.000 1;采用 Adam 优化算法<sup>[18]</sup>加速模型收敛;训练迭代次数设置为 50 次,且引入了早停法,当验证集损失值连续 5 个 Epoch 未改善时终止训练,以防止模型过度拟合。

为解决纤维交叉点检测任务中的类别不平衡问题并满足精确分割的需求,文中提出一种混合损失函数。混合损失函数由 Dice Loss 和 Focal Loss 加权组成,具体公式为

$$L_t = \omega_D \times L_D + \omega_F \times L_F \quad (1)$$

式中: $L_t$  为混合损失函数; $\omega_D$  为 Dice Loss 的权重; $\omega_F$  为 Focal Loss 的权重; $L_D$  为 Dice Loss; $L_F$  为 Focal Loss。

Dice Loss 关注交叉点区域的分割精度,计算公式为

$$L_D = 1 - \frac{2 \times \sum_{i=1}^N p_i \times g_i + \varepsilon}{\sum_{i=1}^N p_i + \sum_{i=1}^N g_i + \varepsilon} \quad (2)$$

式中: $p_i$  为第  $i$  个像素的预测值(范围在 $[0,1]$ ); $g_i$  为第  $i$  个像素的真实标签(0 或 1); $N$  为图像中所有像素的数量; $\varepsilon$  为平滑参数,用于避免预测结果完全错误时出现分母为 0 的情况。

Focal Loss 通过加权机制抑制易分样本的影响,强调困难样本的学习,计算公式为

$$L_F = -\alpha \times (1 - p_i)^\gamma \times \log p_i \quad (3)$$

式中: $p_i$  为模型对正确类别的预测概率; $\alpha$  为平衡因子(默认为 0.25),用于调整正负样本的权重; $\gamma$  为困难样本的权重<sup>[19]</sup>。

为寻找纤维交叉点检测任务中最优的损失函数权重组合和超参数设置,文中对混合损失函数中 Dice Loss 和 Focal Loss 的权重( $\omega_D, \omega_F$ ),以及 Focal Loss 的参数  $\gamma$  进行实验测试。通过分析不同参数组合下模型在验证集的像素准确率、精确率以及训练耗时的表现,选择最优参数,以满足任务需求。像素准确率( $P_A$ )、精确率( $P_P$ ) 计算公式为

$$P_A = \frac{T_P + T_N}{T_P + T_N + F_P + F_N} \quad (4)$$

$$P_P = \frac{T_P}{T_P + F_P} \quad (5)$$

式中: $T_P$  表示预测为纤维,且实际为纤维的像素数; $T_N$  表示预测为背景,且实际为背景的像素数; $F_P$  表示预测为纤维,但实际为背景的像素数; $F_N$  表示预测为背景,但实际为纤维的像素数。

## 3 结果与讨论

### 3.1 模型训练结果

3.1.1 纤维补断模型训练 图 4 为训练集和验证集的损失值变化情况。由图 4 可见,随着训练次数的增加,训练集损失值逐步降低,表明模型的优化效果显著,且在训练后期趋于收敛。但在训练后期验证集损失值趋于波动,甚至出现小幅上升的迹象,表明模型可能开始过度拟合。为避免这种情况,在模型中采用了早停策略。模型在第 37 次训练时触发自动终止。




图 4 训练中损失值变化

Fig. 4 Loss value changes during training

图 5 为模型性能训练中像素准确率与精确率变化情况。由图 5 可见,像素准确率随着训练轮次的增加逐步提升,并在训练后期趋于收敛,验证集的最终像素准确率达到 98.72%。精确率在 90% 左右波动,说明模型不仅能够正确预测大多数像素,还在

少数类纤维区域的预测上表现出色。这表明模型在补断纤维任务中具备良好的判别能力和细粒度特征提取能力。




图 5 训练中像素准确率与精确率变化

Fig. 5 Pixel accuracy and precision changes during training

**3.1.2 纤维交叉检测模型训练** 表 1 为纤维交叉点检测任务中参数与模型性能的关系。由表 1 可见,当  $\omega_D, \omega_F$  权重一致时,模型的像素准确率和精确率表现最佳,同时训练耗时也保持在合理范围内。此

外,适当调整  $\gamma$  能够进一步提升精确率,但可能会导致训练时间增加。因此,文中最终选择了  $\omega_D = 0.5, \omega_F = 0.5, \alpha = 0.25, \gamma = 1$  的组合作为最终的模型参数。

表 1 参数与模型性能的关系

Tab. 1 Relationship between parameters and model performance

$\omega_D$	$\omega_F$	$\gamma$	像素准确率/%	精确率/%	每轮耗时/s
0.3	0.7	2	79.906	74.189	60.86
0.4	0.6	2	90.660	87.601	38.73
0.5	0.5	2	93.190	89.638	52.39
0.6	0.4	2	92.152	89.388	47.45
0.7	0.3	2	90.036	87.332	49.35
0.5	0.5	1	93.921	89.807	51.65
0.5	0.5	3	93.462	89.328	56.12

3.2 纤维测长实验

在纤维补断和交叉点检测模型的基础上,选取 5 组具有不同纤维分布特征的样本进行纤维测长实验,检测纤维分布均匀程度、密集交叉情况,以评估模型的实际应用效果,具体流程如图 6 所示。

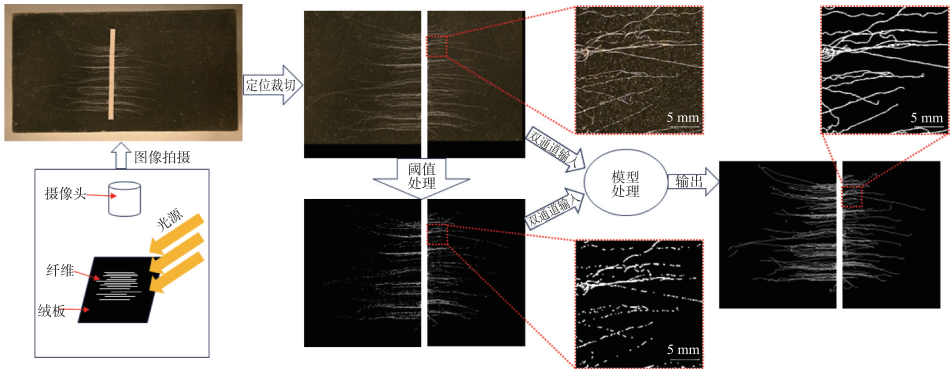


图 6 纤维交叉判断流程

Fig. 6 Fibre crossing judgement process

将补断后的纤维图像输入交叉检测模型中,判断纤维交叉的情况(见图 7),得到重叠部分的纤维像素。




图 7 纤维交叉情况

Fig. 7 Fibre crossing situation

根据补断后的二值图像统计纤维根数。计算方法为:①从图像最左端取一列像素,统计该列从上至下黑白像素的交替次数;②当白色像素连续出现 3 次时,交替次数额外增加 2 次,以补偿纤维相互遮挡可能导致的遗漏;③以 10 像素为步长,在图像宽度范围内重复上述操作,统计所有列的交替次数,最终取交替次数最大值除以 2,作为纤维根数。

平均长度( $\bar{L}$ ) 计算公式为

$$\bar{L} = \frac{P_B + P_1 + P_2}{N_F \times R_s \times W} + 10 \quad (6)$$

式中: $P_B$  为阈值处理后的纤维像素; $P_1$  为补断的纤维像素; $P_2$  为交叉的纤维像素; $N_F$  为成功跟踪的纤维根数; $R_s$  为像素与实际长度的转换比例; $W$  为纤维宽度(默认为 3 像素);中间黑色卡纸的宽度为 10 mm。

基于式(6),对 5 组具有不同纤维分布特征的样本 进行测量,得到羊绒纤维长度,具体测量结果见表 2。

表 2 羊绒纤维长度测量结果

Tab. 2 Measurement results of cashmere fiber length

组别	整体纤维像素	交叉纤维像素	根数	比例/(像素/mm)	平均长度/mm	手排长度/mm	标准差/mm
1	125 387	27 412	147	13.806	35.10	35.88	0.78
2	173 315	32 224	194	13.768	35.65	36.21	0.56
3	177 808	30 888	179	13.921	37.92	37.64	0.28
4	180 223	42 379	190	13.884	38.13	35.15	2.98
5	179 639	36 860	215	13.844	34.25	34.92	0.67

由表 2 可见,各组别的标准差整体较低,除第 4 组外,其余标准差均小于 1,表明模型在纤维长度测量中的稳定性较好,尤其是第 3 组的标准差仅为 0.28,说明模型测量结果与手排法结果的偏差极小,验证了模型在特定样本上的高度准确性。

此外,第 4 组的标准差相对较高,可能与样本中纤维分布的均匀性较差、交叉纤维占比较高有关。图 8 为第 3 组与第 4 组纤维的对比情况。由图 8 可见,与纤维分布均匀的第 3 组相比,第 4 组纤维排布更加密集,且交叉区域显著增多。这种分布特性增加了测量纤维长度时的复杂性,尤其是在交叉点区域,可能带来更多不确定性。

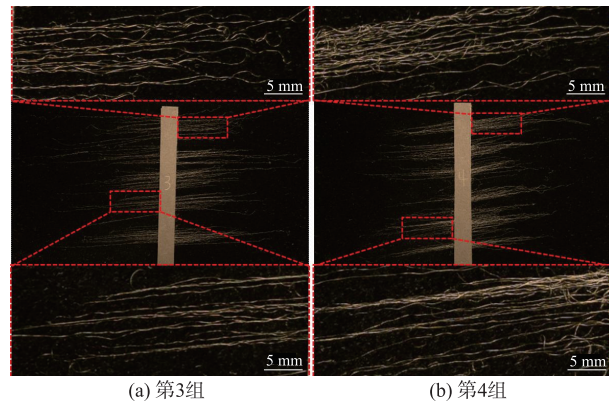


图 8 纤维对比

Fig. 8 Comparison of fibers

为了进一步验证因纤维分布、排布不均导致标准差较高而产生的影响,文中计算了交叉点占比,以分析不同组别样本的分布特点,具体数据见表 3。

表 3 纤维交叉点占比与标准差

Tab. 3 Proportions of fiber intersection and standard deviations

组别	交叉点占比/%	标准差
1	12.8	0.78
2	13.5	0.56
3	14.2	0.28
4	22.4	2.98
5	13.9	0.67

由表 3 可见,第 4 组样本的交叉点占比高达

22.4%,显著高于其他组别的样本。交叉点占比的增加可能会使模型在计算纤维像素与根数时受到干扰,进而导致长度计算的偏差。

尽管第 4 组的标准差明显高于其他组别,但其交叉点占比的变化趋势与整体数据仍保持一致,表明模型对复杂样本具有一定的鲁棒性,但在高密度、复杂纤维分布条件下的稳定性仍有提升空间。

## 4 结语

文中提出了一种基于卷积神经网络的纤维补断与交叉检测模型。该模型利用图像处理技术对采集的图像进行预处理,以提取主要纤维的特征区域;在此基础上,进一步应用卷积神经网络对纤维图像进行纤维主体补断与纤维交叉区域判断,得到纤维长度;最后通过计算得出羊绒的平均长度。研究得出以下结论:

1) 基于 U-Net 框架的纤维补断模型,能够有效修复纤维断点,生成连续的纤维二值图。通过引入跳跃连接和合理的卷积模块设计,模型在特定任务上的像素准确率达到 98.72%,验证了其在纤维补断任务中的良好稳定性和准确性。

2) 采用基于 ResNet-50 编码器的 U-Net 框架构建纤维交叉点检测模型,结合 Dice Loss 和 Focal Loss 设计混合损失函数,在缓解类别不平衡问题的同时提高了纤维交叉点检测的精度。实验表明,模型最终交叉点区域的准确率显著提升,并表现出良好的泛化能力。

3) 在真实样本纤维测长实验中,模型测量的平均纤维长度与手排法结果差异的标准差均保持在合理范围内。特别是对于纤维分布均匀的样本组,标准差低至 0.28,验证了模型的稳定性和实用性。

4) 研究结果表明,文中提出的纤维补断与交叉检测模型能够为羊绒纤维测长任务提供可靠的技术支持,显著降低人工测量的时间成本和误差影响,并为相关研究与应用提供新的思路和参考。未来研究可进一步优化模型性能,将模型应用范围扩展至不同种类纤维的测长。

## 参考文献:

- [1] 潘依诺, 杨春冰, 杜赵群, 等. MXene 基羊绒织物压力传感器的构筑及性能[J]. 现代纺织技术, 2025, 33(10): 115-122.  
PAN Yinuo, YANG Chunbing, DU Zhaoqun, et al. Construction and performance of MXene-based Cashmere fabric pressure sensors [J]. Advanced Textile Technology, 2025, 33(10): 115-122. (in Chinese)
- [2] 穆奎, 刘慧慧, 唐孔科, 等. 基于曲线拟合及积分算法的山羊绒手扯长度检测方法[J]. 毛纺科技, 2024, 52(6): 96-100.  
MU Kui, LIU Huihui, TANG Kongke, et al. Research on the detection method of Cashmere hand-pulled length based on curve fitting and integration algorithm[J]. Wool Textile Journal, 2024, 52(6): 96-100. (in Chinese)
- [3] 戴千惠, 王喻, 陈丽君, 等. 羊绒长度的仪器化检测方法[J]. 东华大学学报(自然科学版), 2020, 46(6): 902-907.  
DAI Qianhui, WANG Yu, CHEN Lijun, et al. A new measuring method for Cashmere length [J]. Journal of Donghua University (Natural Science), 2020, 46(6): 902-907. (in Chinese)
- [4] 方娟, 庞瑞冬, 马爱琴, 等. 双须光电法羊绒测长仪 1.0 版的精确度分析[J]. 毛纺科技, 2020, 48(12): 67-72.  
FANG Juan, PANG Ruidong, MA Ai qin, et al. Analyzing on the accuracy of the double whisker Cashmere length measuring instrument version 1.0 [J]. Wool Textile Journal, 2020, 48(12): 67-72. (in Chinese)
- [5] Standard test method of sampling and testing staple length of grease wool; ASTM D1234—13[S]. Philadelphia: American Society for Testing and Materials, 2013.
- [6] Determination of fiber length and distribution (Almeter method); IWTO -17 -04[S]. London: International Wool Textile Organisation, 2004.
- [7] BRIMS M, BAXTER P. Improving agreement on hauteur measurement between OFDA4000 and Almeter [C]// International Wool Textile Organisation Report. Shanghai: IWTO Technology and Standards Committee Sliver Group, 2004.
- [8] 金敬业, 杨欢, 吴美琴, 等. 基于双端须丛试样的棉毛纤维长度频率分布测量[J]. 东华大学学报(自然科学版), 2018, 44(2): 196-204, 237.  
JIN Jingye, YANG Huan, WU Meiqin, et al. Length-frequency distribution testing of cotton and wool based on dual-beard sample [J]. Journal of Donghua University (Natural Science Edition), 2018, 44(2): 196-204, 237. (in Chinese)
- [9] 中华人民共和国国家质量监督检验检疫总局, 中国国家标准化管理委员会. 纤维长度及其分布参数的测定方法 阿尔米特法: GB/T 21293—2007[S]. 北京: 中国标准出版社, 2007.
- [10] 王喻, 戴千惠, 陈丽君, 等. 双须光电法与手排法测试羊绒长度对比[J]. 毛纺科技, 2020, 48(1): 9-13.  
WANG Yu, DAI Qianhui, CHEN Lijun, et al. Comparison of double whisker measurement method and manual row test result for Cashmere length [J]. Wool Textile Journal, 2020, 48(1): 9-13. (in Chinese)
- [11] 杨传颖, 高荣贵, 石宝, 等. 基于图像处理的分梳山羊绒长度检测方法[J]. 毛纺科技, 2020, 48(2): 68-72.  
YANG Chuanying, GAO Ronggui, SHI Bao, et al. Test method for carding cashmere length based on image processing [J]. Wool Textile Journal, 2020, 48(2): 68-72. (in Chinese)
- [12] 刘正, 吴诗豪, 侯珏, 等. 基于数据增强和改进卷积神经网络的织物纬斜检测[J]. 服装学报, 2023, 8(5): 391-399.  
LIU Zheng, WU Shihao, HOU Jue, et al. Fabric skewing detection based on data augmentation and improved convolutional neural network [J]. Journal of Clothing Research, 2023, 8(5): 391-399. (in Chinese)
- [13] 韩曙光, 姜凯文, 赵丽妍. 基于深度学习的服装三要素识别[J]. 服装学报, 2022, 7(5): 399-407.  
HAN Shuguang, JIANG Kaiwen, ZHAO Liyan. Recognition of clothing "three elements" based on deep learning [J]. Journal of Clothing Research, 2022, 7(5): 399-407. (in Chinese)
- [14] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks [J]. Communications of the ACM, 2017, 60(6): 84-90.
- [15] RONNEBERGER O, FISCHER P, BROX T. U-Net: convolutional networks for biomedical image segmentation [C]//International Conference on Medical Image Computing and Computer-Assisted Intervention. Cham; Springer International Publishing, 2015: 234-241.
- [16] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition [C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas: IEEE, 2016: 770-778.
- [17] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation [C]//2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Boston: IEEE, 2015: 3431-3440.
- [18] KINGMA D P, BA J L. Adam: a method for stochastic optimization [C]//3rd International Conference for Learning Representations. San Diego: ICLR, 2015: 1-15.
- [19] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection [C]//2017 IEEE International Conference on Computer Vision (ICCV). Venice: IEEE, 2017: 2999-3007.

(责任编辑:沈天琦)