 DOI: https://doi.org/10.12345/bdai.v5i8.20935

Optimization of the Fabric Defect Detection Algorithm Based on Deep Learning

Luxiao Zhu　Lisai Luo

Shaanxi Fashion Engineering University, Xianyang, Shaanxi, 712046, China

Abstract

This paper proposes a deep learning-based fabric defect detection algorithm optimization scheme to improve the overall performance of the algorithm while realizing the fabric defect detection. This paper first analyzes the key technologies used in the field of defect detection, and reveals the limitations of the existing scheme, and then designs a new network architecture that combines effective feature extraction and optimization strategies. Through comparing experiments, we find that the optimized algorithm can significantly improve the accuracy and efficiency of fabric defect detection. The research of this paper will not only help to promote the development of fabric defect detection technology, but also provide strong support for the intelligent production of textile industry.

Keywords

deep learning; fabric defect detection; algorithm optimization

基于深度学习的织物缺陷检测算法优化

朱鲁晓　罗李赛

陕西服装工程学院，中国·陕西 咸阳 712046

摘　要

论文提出了一种基于深度学习的织物缺陷检测算法优化方案，在实现织物缺陷检测的同时提高算法的整体性能。论文首先分析了缺陷检测领域所用到的关键技术，并揭示了现有方案的局限性，随后设计出一种结合了有效的特征提取和优化策略新型的网络架构。通过对比实验，我们发现优化后的算法能够显著提高织物缺陷检测的准确性和效率。论文的研究不仅有助于推动织物缺陷检测技术的发展，也将为纺织行业的智能化生产提供有力的支持。

关键词

深度学习；织物缺陷检测；算法优化

1 引言

在纺织行业中，织物的质量直接影响着产品的最终品质和消费者的满意度。消费者对产品的质量要求越来越高，织物缺陷检测的准确性成为确保产品质量的重要环节。传统的织物缺陷检测方法主要依赖于人工视觉检查或简单的图像处理技术，这些方法既耗时费力又容易受到主观因素的影响，导致检测效率低且准确性欠佳。随着计算机视觉技术的进步，特别是深度学习算法的应用，基于机器视觉的织物缺陷检测技术取得了显著进展，为实现自动化、高精度的织物缺陷检测提供了新的解决方案。目前，基于深度学习的织物缺陷检测技术已经显示出其在提高检测速度和准确度方面的巨大潜力。这些方法通常利用各种神经网络来自动提取织物表面的特征并通过训练得到的模型来进行缺陷识别。但在实际应用中现有的基于深度学习的方法仍存在一些问题，如对小尺寸缺陷的检测能力不足、对复杂背景下的缺陷识别不够准确等。不仅如此，如何有效地利用有限的标注数据来训练高性能的模型也是一个挑战。

2 相关工作融合

2.1 关键技术回顾

深度学习技术的迅猛发展为织物缺陷检测带来了革命性的变化，其中卷积神经网络（Convolutional Neural Networks，CNNs）凭借在图像识别任务上的卓越表现而成为这一领域的核心工具。CNNs 能够从原始图像中自动提取多级特征。循环神经网络（Recurrent Neural Networks，RNNs）也被用于处理具有序列依赖性的缺陷检测任务，它在连续织物材料的检测中展现出独特的优势。值得注意的是，一些特定的深度学习模型（如 U-Net 和 ResNet）因其在网络结构上的创新而在图像分类和分割领域取得了显著

【基金项目】陕西服装工程学院校级科研项目，2023XKR53，基于深度学习的织物缺陷检测算法优化。

【作者简介】朱鲁晓（1997–），女，中国河南平顶山人，硕士，工程师，从事深度学习、智能视觉信息处理研究。

的成功。U-Net 通过引入编码器 - 解码器架构和跳跃连接极大地提高了模型在图像分割任务中的性能 [1]；而 ResNet 借助残差学习框架解决了深层网络的梯度消失问题，使得模型能够有效训练更深的网络结构，模型的学习能力和泛化能力都得到了提升。

2.2 现有方案的局限性

现有基于深度学习的织物缺陷检测方法已经展现出了强大的潜力，它们能够在一定程度上有效识别不同类型和大小的缺陷，并且在大规模数据集上取得了较高的准确率，但我们也不得不正视已有算法的局限性。一方面，细微缺陷的检测仍然是一个挑战，尤其是当这些缺陷与周围正常织物纹理相似时。另一方面，由于织物材料种类繁多且缺陷形态各异，单一的模型往往难以适应所有类型的织物。对于复杂背景下的缺陷检测，现有方法的表现也有待提高。因此，开发一种在处理小尺寸缺陷和复杂背景的情况下更加鲁棒和通用的织物缺陷检测算法，仍然是当前研究的重点之一。

3 算法优化

3.1 数据集准备

为了确保模型的有效性和可靠性，本实验精心构建了一个包含多种类型织物缺陷的高质量数据集。数据集的构建过程涉及以下几个关键步骤。

3.1.1 样本收集

实验从多个织物生产商处收集了大量带有各种缺陷的织物样本，这些样本涵盖了常见的织物缺陷类型，包括但不限于孔洞、污渍、纤维断裂、色差、条纹不齐等。为了覆盖尽可能广泛的缺陷类型，实验特意选择了不同材质（如棉、麻、丝、合成纤维等）和颜色的织物样本以确保模型能够在多种条件下有效识别缺陷。最终的数据集包含了超过 5000 张高清图像，每张图像均包含至少一处缺陷。将这些图像分为不同的类别，这样一来模型便能学习到不同类型的缺陷特征。举例来讲，孔洞类缺陷被标记为一类而污渍类缺陷则被标记为另一类。本实验还特别关注了罕见缺陷的收集以防止模型因训练数据不足而忽视这类缺陷的检测。

3.1.2 数据预处理

为了消除噪声并提高模型性能，对原始图像进行预处理。所有图像被调整至统一的尺寸（如 512×512 像素）以保证模型输入的一致性。随后对某些特定的织物类型进行灰度转换处理，这有助于减少颜色对模型的影响，使模型更专注于纹理特征。我们还对图像进行了亮度和对比度的调整以适应不同光照条件下的织物图像。

3.1.3 数据划分

数据集被随机划分为训练集、验证集和测试集，比例分别为 70%、15% 和 15%。训练集用于模型的学习阶段；验证集可以监控模型训练过程中的表现并指导参数的调整；而测试集则保留用于最终评估模型的性能，确保模型在未见过的数据上依然能够保持良好的检测效果。

3.2 模型架构设计

优秀的深度学习模型架构有利于实现高效的织物缺陷检测，论文的架构综合了卷积神经网络（CNN）的优势，并针对织物缺陷检测的特点进行了优化。

在输入层中，模型接收标准尺寸的 RGB 图像作为输入，这些图像经过预处理以确保模型能够稳定地学习特征。特征提取模块由一系列卷积层组成，用于提取织物图像中的局部特征。为了增强模型的特征提取能力，我们采用了具有不同大小的感受野的卷积核来捕获不同尺度的特征。考虑到织物缺陷往往较小且不易察觉，在模型中引入注意力机制来辅助模型专注于缺陷区域 [3]。通过使用自注意力层，模型能够学习到哪些特征图对缺陷检测更为重要。模型的最后一层负责对缺陷进行分类和定位，多任务学习策略可以让模型能够同时预测缺陷的类别和位置坐标。激活函数方面，SELU 被广泛应用于隐藏层以引入非线性，而 Swish 激活函数主要在输出层生成概率分布形式的分类结果。

3.3 模型训练与优化

在模型训练阶段，我们采取了一系列优化措施，确保模型既能快速收敛又能有效避免过拟合。

不同类别之间的样本存在不均衡问题，为此我们采用了加权的交叉熵损失函数。在织物缺陷检测中，不同类型的缺陷可能在数据集中出现的频率大相径庭，可能导致模型倾向于预测那些出现频率较高的缺陷。因此，我们为每个类别的损失函数分配了不同的权重，这样模型在训练过程中对所有类型的缺陷给予同等的关注。为了更好地定位缺陷，我们还加入了边界框回归损失，这有助于模型精确地确定缺陷的位置。

Adam 优化器被选为训练过程中的优化算法，因为它能够自动调整学习率并且在实践中表现出良好的性能。它结合了动量（Momentum）和自适应学习率（Adaptive Learning Rate）的优点，通过计算梯度的一阶矩估计（移动平均）和二阶矩估计（无偏方差）来更新模型参数。这种优化器能够有效地应对训练过程中遇到的非平稳性和稀疏性问题。L2 正则化在训练过程可以有效避免过拟合。它通过向损失函数中添加权重的平方和的惩罚项来抑制权重过大，从而减少了模型的复杂度。但要注意对正则化系数进行反复调整，找到一个合适的平衡点，既能防止过拟合，又不会过度简化模型，导致欠拟合 [2]。

针对学习率调度，本研究使用学习率衰减策略来加速收敛并找到最优解。初始学习率设置较高以加快模型学习的速度，随着训练轮次的增加，学习率逐渐降低。这种策略有助于模型在训练初期快速找到大致的最优解方向，在后期更加精细地调整参数并获得更高的精度。学习率衰减策略是动态变化的，即根据验证集上的性能变化来调整学习率。为了加速训练过程并提高模型的稳定性，我们在每一层之后应用了批量归一化（Batch Normalization）。批量归一化就是对

每个小批量数据的激活值进行归一化处理，主要用于减少内部协变量偏移问题，它还能在一定程度上起到正则化的作用，减少对 Dropout 的需求。

通过网格搜索和随机搜索相结合的方式对模型的关键超参数进行了细致的调整，这些超参数包括学习率、正则化系数、批量大小、网络层数等。首先利用网格搜索确定了几个关键超参数的大致范围，然后通过随机搜索进一步精炼这些超参数，最终找到最佳组合。不同超参数之间的相互作用也需要纳入考量，确保整个模型配置的最优性 [1]。

4 实验结果与讨论

4.1 实验设置

实验是在配备 NVIDIA GeForce RTX 3090 GPU 的工作站上进行的，该工作站拥有 24GB 显存和 64GB 系统内存，操作系统为 Ubuntu 20.04 LTS。同时借助 PyTorch 深度学习框架来实现所提出的模型。在评估模型性能方面，采用了包括准确率、召回率和 F1 分数在内的多种常用的评估指标。准确率衡量了模型正确分类的比例；召回率反映了模型识别出的正例占所有实际正例的比例；而 F1 分数则是准确率和召回率的调和平均值，能够综合反映模型的性能。实验主要将研究所提出的模型和两种基准模型（GANs 和 LSTM）进行对比分析，分别是记作基准模型 A 和基准模型 B。

4.2 结果展示

实验结果表明，所提出的织物缺陷检测算法在各种指标上均表现出色。我们通过表格和图形直观地展示了实验结果，以便读者更好地理解模型的性能。

无论是准确率、召回率还是 F1 分数，本研究所提出的优化模型都强于两个基准模型。

如图 1 所示，所提出的模型在 ROC 曲线上表现出更高的曲线下面积（Area Under the Curve，AUC），这进一步证实了模型在织物缺陷检测任务上的优越性能。

4.3 结果分析与讨论

实验结果表明，所提出的织物缺陷检测算法不仅能有效地识别出织物缺陷，还能保持较高的准确率。尽管所提出的模型在多项指标上表现出色，但仍存在一些局限性需要指出。对于某些非常规的织物类型，在样本数量较少的情况下模型的性能可能会下降。另外，模型对光照条件的变化较为敏感，这意味着在实际部署时需要考虑环境光的影响。针对上述局限性，未来的研究可以从以下几个方面进行改进：一是通过增加更多样化的织物样本进一步增强模型的泛化能力；二是探索更加复杂的特征提取方法，提高对微小缺陷的识别能力；三是研究光照不变性技术来减轻光照条件变化对模型性能的影响 [2]。

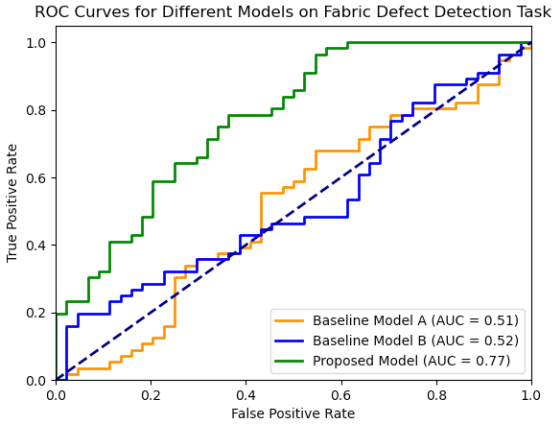

图 1 不同模型在测试集上的 ROC 曲线

4.4 应用前景

鉴于前面所分析的技术优势，本研究提出的织物缺陷检测算法展现出广阔的应用前景。在纺织行业，该技术能够集成到现有的生产线中，在实现高速连续的在线质量监控的基础上显著降低因人工检查导致的成本和误差。例如，将带有优化算法的系统部署于高速织造机旁，这样便能在生产过程中即时识别并标记有瑕疵的织物段落，及时干预以减少废品率。长远来看，该技术将在更多领域得到推广应用，如汽车内饰材料的质量控制、服装面料的分级筛选等，为整个产业链带来显著经济效益的同时也推动了智能纺织技术的发展进程 [3]。

5 结语

论文所提出的针对织物缺陷检测的深度学习算法优化方案能够显著提高检测的准确性和效率。优化后的算法相较于现有方法，在准确率、召回率和 F1 分数等关键指标上均有提升。但模型仍面临一些局限性，尤其是在处理非常规织物类型和适应不同光照条件方面。未来，需要将进一步增强模型的泛化能力和鲁棒性。总体而言，本研究不仅推进了织物缺陷检测技术的发展，也为纺织行业的智能化升级提供了强有力的技术支持，具有重要的理论意义和应用价值。

参考文献

[1] 吴甘文祥.基于深度学习的织物缺陷检测算法研究[D].芜湖:安徽工程大学,2023.

[2] 康雪娟.基于机器学习的织物缺陷检测方法研究[D].西安:西安理工大学,2022.

[3] 王理顺,钟勇,李振东,等.基于深度学习的织物缺陷在线检测算法[J].计算机应用,2019,39(7):2125-2128.