

融合密集卷积网络和迁移学习的张拉膜结构膜面损伤智能识别分类

贾智扬^{1,2}, 喻秋^{1*}, 张营营², 段志国², 张可欣², 赵子曦², 王建祥²

¹中国矿业大学计算机科学与技术学院/人工智能学院, 江苏 徐州

²中国矿业大学力学与土木工程学院, 江苏 徐州

收稿日期: 2026年4月19日; 录用日期: 2026年5月11日; 发布日期: 2026年5月20日

摘要

膜面破损容易引发张拉膜结构发生瞬时破断和溃塌, 针对传统方法依赖人工目视检测普遍存在主观性强、效率低等问题, 本文提出一种膜面损伤识别分类的密集卷积网络深度学习框架(DenseNet121-ECA-PTL)。首先, 以自主构建的典型张拉膜试验平台为基础, 建立包含5种典型膜面损伤类型的张拉膜结构膜面损伤图像数据集; 其次, 为提升对早期微小损伤的表征能力, 在DenseNet121模型密集连接块中嵌入高效通道注意力模块, 增强模型对损伤区域关键特征的聚焦能力; 最后引入迁移学习策略优化模型收敛性能, 并进行了模型对比试验用以验证模型改进效果。结果表明: 本文提出的DenseNet121-ECA-PTL模型有效提升了基础模型在膜面细微特征高效提取能力, 在测试集上的识别准确率达到98%, 单张图像推理耗时仅为0.04 s。该算法在保证高精度的同时具备优异的推理效率, 为张拉膜结构膜面损伤的智能化监测与移动端实时部署提供坚实的技术支持。

关键词

膜面损伤, 智能分类, 密集卷积网络, 注意力机制, 迁移学习

Intelligent Identification and Classification of Membrane Damage in Tensile Membrane Structures Based on Dense Convolutional Networks and Transfer Learning

Zhiyang Jia^{1,2}, Qiu Yu^{1*}, Yingying Zhang², Zhiguo Duan², Kexin Zhang², Zixi Zhao², Jianxiang Wang²

¹School of Computer Science and Technology/School of Artificial Intelligence, China University of Mining and

*通讯作者。

文章引用: 贾智扬, 喻秋, 张营营, 段志国, 张可欣, 赵子曦, 王建祥. 融合密集卷积网络和迁移学习的张拉膜结构膜面损伤智能识别分类[J]. 土木工程, 2026, 15(5): 227-237. DOI: 10.12677/hjce.2026.155133

Abstract

Membrane damage can easily lead to instantaneous rupture and progressive collapse of tensile membrane structures. Traditional methods relying on manual visual inspection are commonly characterized by strong subjectivity and low efficiency. This study proposes a dense convolutional network-based deep learning framework (DenseNet121-ECA-PTL) for membrane damage identification and classification. Firstly, the dataset containing five typical types of membrane damages was constructed based on the typical tensile membrane structure experimental platform. Secondly, an Efficient Channel Attention (ECA) module was embedded into the dense blocks of DenseNet121 to enhance the representation capability for early-stage micro-damage. Finally, a transfer learning strategy was introduced to improve convergence performance, and comparative experiments were conducted to validate the effectiveness of the proposed model. The results demonstrate that the DenseNet121-ECA-PTL improves the feature extraction capability of the baseline model for subtle damage characteristics. The proposed model achieves an accuracy of 98% on the test dataset, with an inference time of 0.04 s per image. Furthermore, the proposed model exhibits excellent computational efficiency while maintaining high accuracy, providing strong technical support for intelligent monitoring and real-time mobile deployment of membrane damage detection in tensile membrane structures.

Keywords

Membrane Damage, Intelligent Classification, Dense Convolutional Network, Attention Mechanism, Transfer Learning

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

张拉膜结构作为典型的新型大跨度空间体系，依靠涂层织物膜材料与支撑结构间的预张应力维持形态并承载外荷载[1]。膜材作为核心受力单元，其性能退化或局部破损极易诱发体系连锁失效甚至整体溃塌[2]。随着我国早期建成的百余座大型膜结构工程相继进入服役中后期，膜面损伤的健康监测亟需引起膜结构研究领域专家学者们重视。然而，现有的监测手段仍高度依赖人工巡检，存在主观干扰大、高空作业危险及细微损伤易漏检等局限。尽管基于振动响应的检测技术已广泛应用[3]-[5]，但膜结构具有极高的柔性与几何非线性，局部微小损伤对整体模态参数影响微弱，仅凭低维振动信号难以实现褶皱、污渍及撕裂等复杂损伤类型的精确分类。而计算机视觉技术能够获取包含丰富空间信息的图像或视频数据，具有非接触、高分辨率及损伤可视化的显著优势。近年来，便携式成像设备的普及为大规模采集膜面损伤图像提供了技术基础，也为实现张拉膜结构损伤的智能化、多维度识别提供了检测新途径。

近年来人工智能领域的不断发展，卷积神经网络模型展现出强大的特征提取与识别能力，已经为土木工程领域结构健康监测提供了新的解决方案。Ritzky [6]通过迁移学习对多种先进卷积神经网络模型进行

微调,验证了在有限数据集下实现高鲁棒性裂缝识别的可行性; Bouguettaya [7]进一步证明了迁移学习与集成策略在热轧钢带等工业场景缺陷分类中的卓越性能; 针对复杂检测环境及自动化检测方面, Gadiraju [8]融合深度强化学习与迁移学习构建了 SHM-Traffic 框架,实现了通车状态下的无人机高精度、高效自主巡检。为进一步提升鲁棒性,学者引入注意力机制对深度学习模型进行性能改进, Sarhadi [9]引入 SWIN U-Net 架构,利用 Transformer 的全局建模能力显著提升了微细裂缝的检测效率。针对卷积神经网络模型的层数递增过程中容易出现深层网络梯度消失问题, Huang [10]的密集连接卷积网络很好地解决了上述问题。可见,深度学习算法是实现张拉膜结构膜面损伤无人化、智能化检测的理想方法之一。然而,基础 DenseNet 存在关键区域聚焦不足、特征区分度低等局限,针对张拉膜结构膜面损伤检测问题时面临识别背景复杂、早期微小损伤表征能力弱等挑战。迁移学习作为一种知识共享机制,可有效加速模型收敛并提升识别精度[11],引入高效通道注意力机制[12]进一步增强了模型对损伤区域的表征能力。

基于此,本文以 DenseNet121 模型为基础架构,提出了一种融合高效通道注意力机制和迁移学习策略改进的张拉膜结构膜面损伤智能分类方法。基于膜结构技术规程,创新性地建立了涵盖 5 种(撕裂、褶皱、污渍、遮挡物及划损)典型损伤类型的膜面损伤数据集,为模型训练提供了丰富的数据基础。根据膜面损伤识别分类问题存在识别背景复杂、早期微小损伤表征能力弱等问题,在 DenseNet121 模型密集连接块处引入高效通道注意力机制,增强关键损伤特征信息的传递,抑制背景噪声及贡献度低的冗余特征,并结合利用迁移学习策略对模型进行微调,进一步提高模型的识别性能与泛化能力,并进行了模型对比试验用以验证模型改进效果。

2. 理论基础

2.1. 密集卷积网络

在计算机视觉领域,卷积神经网络已成为主流方法,能够通过深层结构有效提取图像的高层特征,从而提升分类精度。DenseNet 在 ResNet 的基础上采用密集连接方式,将前层特征直接传递至后续各层,实现特征复用,增强了特征传播能力并提高了模型效率。DenseNet 网络主要由两大核心模块组成:

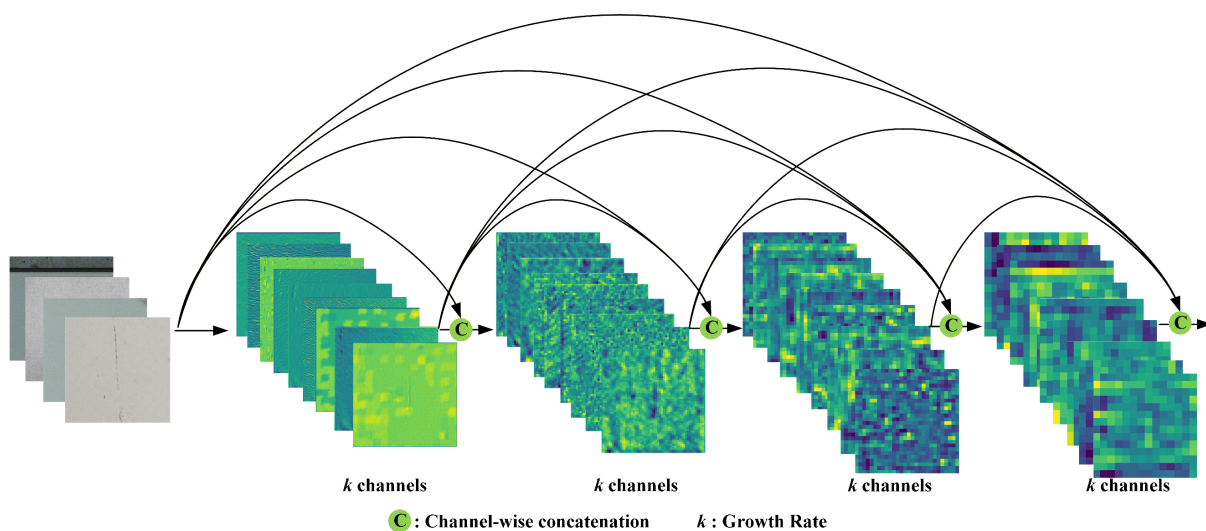


Figure 1. Diagram of the Dense Block

图 1. Dense Block 示意图

第一是密集连接层(Dense Block),密集连接块中每一层会以前面所有层的特征图作为输入,利用通

道拼接实现特征重用，如图 1 所示。该设计确保了低阶特征能够直接传递至高阶层，有效缓解梯度消失的同时强化了特征传播。这种通过拓扑结构优化而非单纯增加网络深度或宽度的策略，显著提升了模型的代表能力。

第二是过渡层(Transition layers)，用于连接相邻的 Dense Block。通过 1×1 卷积核降低特征图通道数，并结合平均池化层进行下采样，从而显著减少了模型参数数量和复杂度。相比于传统神经网络，DenseNet 网络有效缓解了梯度消失问题，增强特征传播与复用，在大幅降低参数规模的同时提升模型性能。本文采用 DenseNet121 作为骨干网络，由 4 个密集连接块和 3 个过渡层组成，在保证膜面损伤特征提取能力的同时，兼顾训练与推理效率。此外，DenseNet121 相较于同系列模型在精度与模型规模之间具有较优平衡，有利于后续模型的轻量化部署。

2.2. 高效通道注意力机制

注意力机制通过强化重要特征、抑制无关信息，自适应分配特征权重，从而提升深度学习模型的特征表达能力。高效通道注意力机制 ECA-Net (Efficient Channel Attention)通过建立通道与权重之间的直接映射关系，提出一种无需降维的局部跨通道交互机制，并采用一维卷积实现高效建模，如图 2 所示。相较于 SE-Net 和 CBAM 等基于全局池化生成通道权重的方法，ECA-Net 在原始通道维度上引入一维卷积，实现相邻通道的局部交互，如公式(1)所示，使得通道权重同时考虑全局信息和局部信息，避免了通道降维带来的信息损失，从而提升模型对微小关键特征的感知能力。在膜面损伤分类任务中，不同损伤类型通常表现为细微的颜色与纹理差异，ECA-Net 通过增强通道特征响应，提高模型对微小损伤特征的辨识能力，从而实现更准确的分类结果。

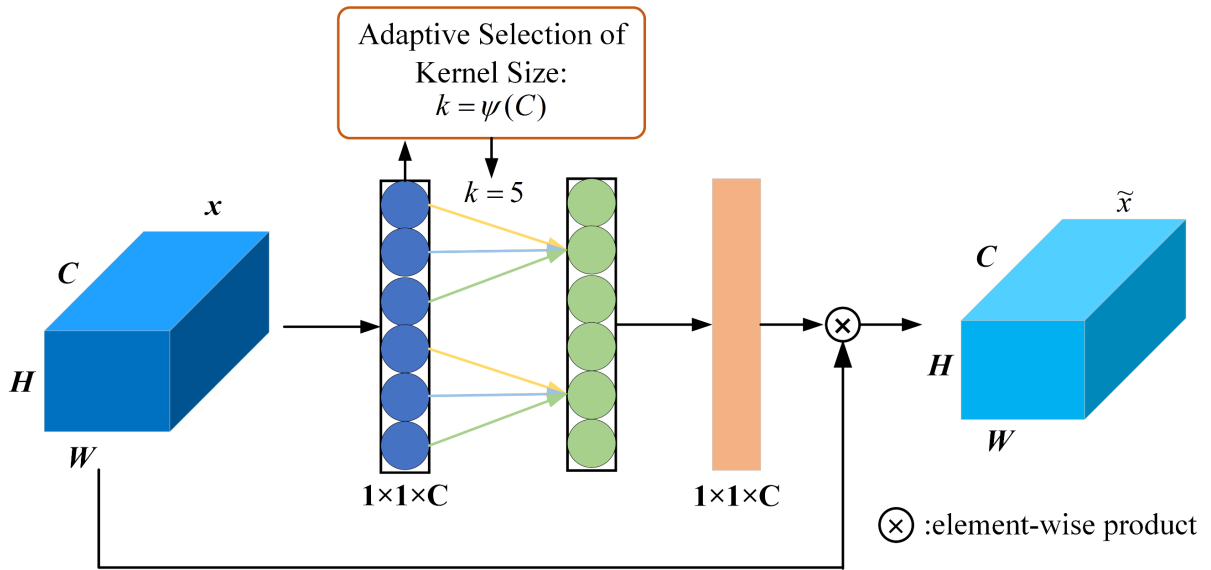


Figure 2. Diagram of ECA-Net efficient channel attention mechanism module

图 2. ECA-Net 高效通道注意力机制模块示意图

$$\omega = \delta(\text{CID}(y)) \tag{1}$$

式中： ω 为通道权重， δ 为激活函数，CID 为一维卷积，交互的覆盖范围(即一维卷积的核大小 k)与通道维度 C 成正比。根据特征图的通道数计算来确定自适应的一维卷积核大小。输入特征图通道数越多，通道数 C 的数量以 2 的次幂形式增加。

2.3. 迁移学习

迁移学习是一种深度学习方法，其作用原理是将在大数据中已训练模型的权重迁移至目标任务中，可在有限样本条件下提升模型性能并降低训练成本。本文采用基于 ImageNet 预训练的模型权重，并在膜面损伤图像数据集上进行迁移与微调，用来提取损伤膜面的关键特征。该方法有效减少了模型对大规模标注数据和计算资源的依赖，使模型无需从头训练即可实现高效学习。

2.4. 模型评价指标

评估指标是用于评价深度学习模型性能的定量指标。它们用于比较不同算法模型在特定任务上的性能，综合评估算法模型解决特定问题的有效性。在本文研究工作中使用的五种评估指标包括：精确率 (*Precision*)、召回率 (*Recall*)、*F1score* 以及马修斯相关系数 (*MCC*)。同时结合混淆矩阵对分类结果进行综合分析。

精确度是预测为正样本中实际为正样本的比例，其数学表示如公式(2)所示。

$$Precision = \frac{TP}{TP + FP} \quad (2)$$

召回率是实际正样本中被正确识别的比例，其数学表示如公式(3)所示。

$$Recall = \frac{TP}{TP + FN} \quad (3)$$

F1score 是精确度和召回率的调和平均值，其数学表示如公式(4)所示。

$$F1score = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (4)$$

马修斯相关系数用于综合衡量分类模型预测性能，其数学表示如公式(5)所示。

$$MCC = \frac{TN \times TP - FN \times FP}{\sqrt{(TN + FP)(FN + TP)(TN + FN)(TP + FP)}} \quad (5)$$

式中，高精度、召回率、*F1score* 和马修斯相关系数能够验证深度学习模型对特定任务数据集具有很好的智能分类识别性能。混淆矩阵是分类模型预测结果的汇总形式，有助于衡量不同的评估指标，通过分析每个类别的正确和不正确预测数量来总结模型的总体性能。

3. 改进 DenseNet121-ECA-PTL 模型

本文提出基于 DenseNet121-ECA-PTL 网络架构的损伤膜面分类主要包括以下步骤：

步骤 1：完成搭建平面张拉膜结构和伞形张拉膜结构两种典型膜结构试验台，采用手机拍摄图像采集手段采集两种膜结构撕裂、褶皱、污渍、遮挡物和划损共计五种不同膜面损伤类型图像数据；

步骤 2：将采集的 5 种膜面损伤图像裁剪至 $224 \times 224 \times 3$ 的彩色图像，并按照类别归类，完成搭建五种膜面损伤图像数据库；

步骤 3：基于手机拍摄搭建的五种膜面损伤彩色图像数据库按照 8:2 比例构建训练集和测试集。将训练集输入 DenseNet121-ECA-PTL 网络，模型中的密集连接网络将模型权重层搭配残差映射，使得网络底层的误差通过快捷连接方式传递给下一层，加快网络模型收敛速度并获取预训练模型。将测试集输入到训练好的 DenseNet121-ECA-PTL 网络中，输出不同损伤膜面分类结果；

步骤 4：根据输出结果确定损伤类型，根据各种指标评估模型推理性能，结合模型推理时间评判模型的预测效率。按照上文所述方法构建深度学习模型，其推理及应用过程如图 3 所示。

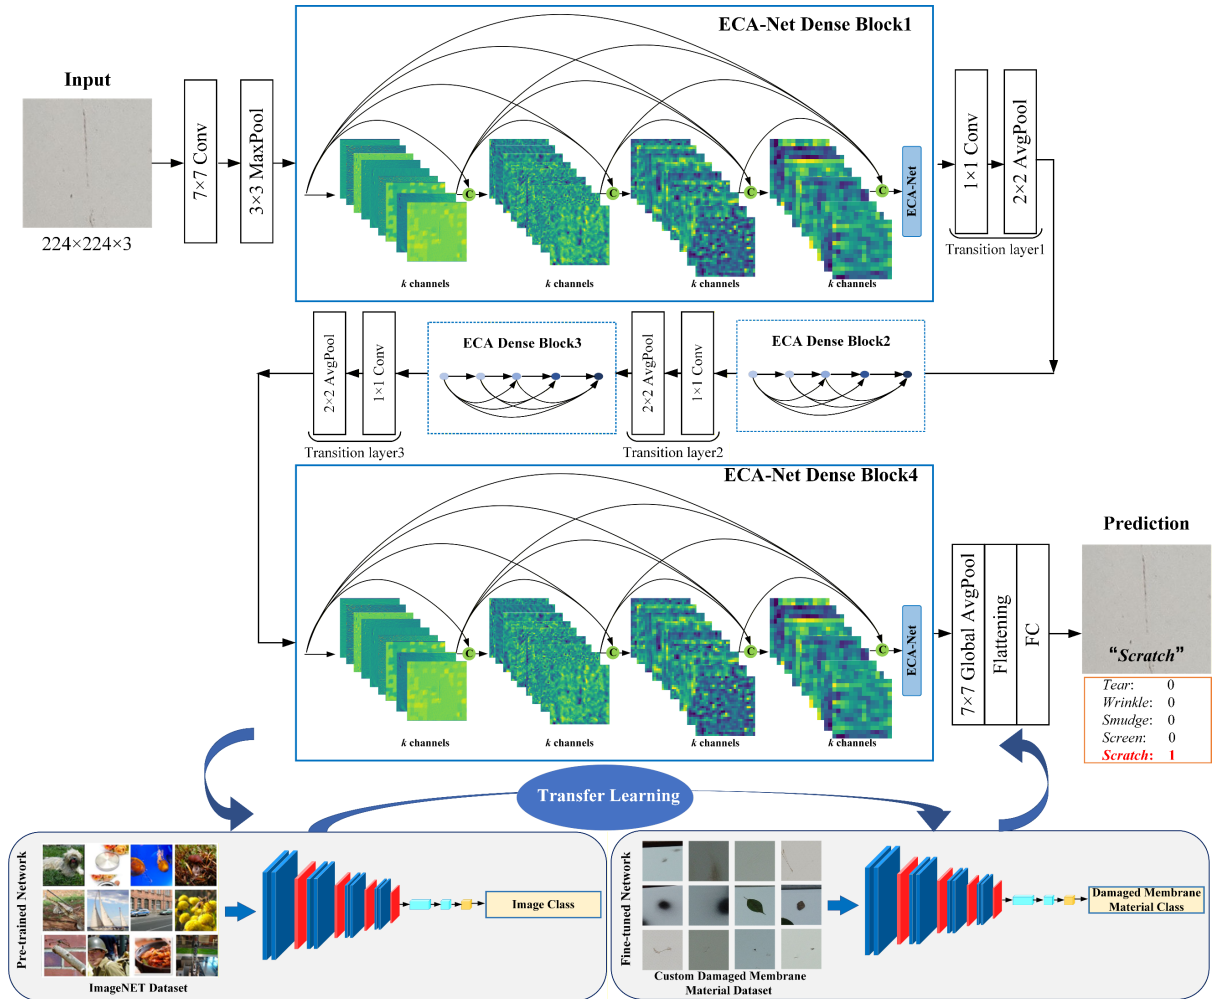


Figure 3. Diagram of the improved DenseNet121-ECA-PTL dense convolutional network model

图 3. 改进 DenseNet121-ECA-PTL 密集卷积网络模型示意图

4. 结果与讨论

4.1. 张拉膜结构实验平台及膜面损伤图像数据集搭建

考虑到现实生活中常用的张拉膜结构样式种类，分别完成搭建平面张拉膜结构和伞形张拉膜结构两种典型张拉膜结构作为本文研究对象。典型张拉膜结构膜面损伤图像数据采集实验平台主要由平面张拉膜结构、伞形张拉膜结构和小米 Redmi Note12 Turbo 智能手机组成，如图 4 所示。两种膜结构膜面均采用 250T PVC 膜材，其力学参数如表 1 所示。

Table 1. Mechanical parameters of the 250T PVC membrane material

表 1. 250T PVC 膜材力学参数

材料类别	厚度 (mm)	面密度 (g/m ²)	抗拉强度 (kN/m)		弹性模量 (N/mm)		泊松比
			经向	纬向	经向	纬向	
250T	0.87	1046	112	94	996	840	0.2




Figure 4. Diagram of the typical tensile membrane structures
图 4. 典型张拉膜结构示意图

参考行业标准《膜结构技术规程》(CECS 158: 2015)中对索膜结构膜面日常检查维护项目要求, 本文将规范要求对膜面的检查维护指标总结归纳为五种: 撕裂、褶皱、划损、污渍和遮挡物。选取典型的单向张拉膜结构和伞形张拉膜结构作为研究对象, 采用手机采集膜面损伤图像, 如图 5 所示。对原始图像进行筛选与重采样, 统一裁剪为 $224 \times 224 \times 3$ 的标准彩色图像。构建的初始数据库包含 10,000 张样本, 其中五类损伤特征各占 20%, 实现了严格的类别均衡。为进一步提升模型的泛化能力与抗噪性, 采用翻转、随机旋转及添加噪声等数据扩增手段, 将数据集规模扩充至 40,000 余张。




Figure 5. Damaged membrane images under different lighting conditions
图 5. 不同光照条件下损伤膜面图像

4.2. 试验环境与模型训练

本文实验模型训练在 Windows10 操作系统上使用 Pytorch 深度学习框架, 硬件配置包括: 12th Gen Intel(R) Core(TM) i7-12700F 处理器, 主频为 2.10 GHz, 32 GB 内存, 以及 NVIDIA GeForce RTX 3060 Ti 显卡。训练过程中使用迁移学习技术提高模型的训练速度, 具体超参数设置如下: 批次大小为 32, 学习率为 0.01, 采用 SGD 优化器, 训练周期为 100 轮。模型输入图片大小设置为 $224 \times 224 \times 3$ 的彩色图像, 对增广后的损伤膜面图像数据库按照 8:2 比例将数据集分为训练集与验证集进行训练。为验证所选出的 DenseNet121 模型的合理性和有效性, 在使用相同数据集、同样的预处理和模型参数条件下, 进行多批次消融实验对比研究。本文研究的图像分类主流模型主要包括: GoogleNet、MobileNet、MnasNet、ShuffleNet、EfficientNet 以及 DenseNet 模型。采用精确度、召回率、特异性、和马修斯相关系数以及混淆矩阵和单张图片的计算时间作为评价指标。

4.3. 结果分析与讨论

4.3.1. 改进模型训练及测试性能

为验证本文提出的 DenseNet121-ECA-PTL 模型在张拉膜结构不同膜面损伤分类任务的优越性, 分别选取 GoogleNet、MobileNet、MnasNet、ShuffleNet、EfficientNet、DenseNet121 和 DenseNet121-ECA 七个图像分类模型进行对比研究。图 6 为基于典型张拉膜结构五种不同膜面损伤图像数据集的 8 个模型训练和测试的损失率和准确率变化曲线。

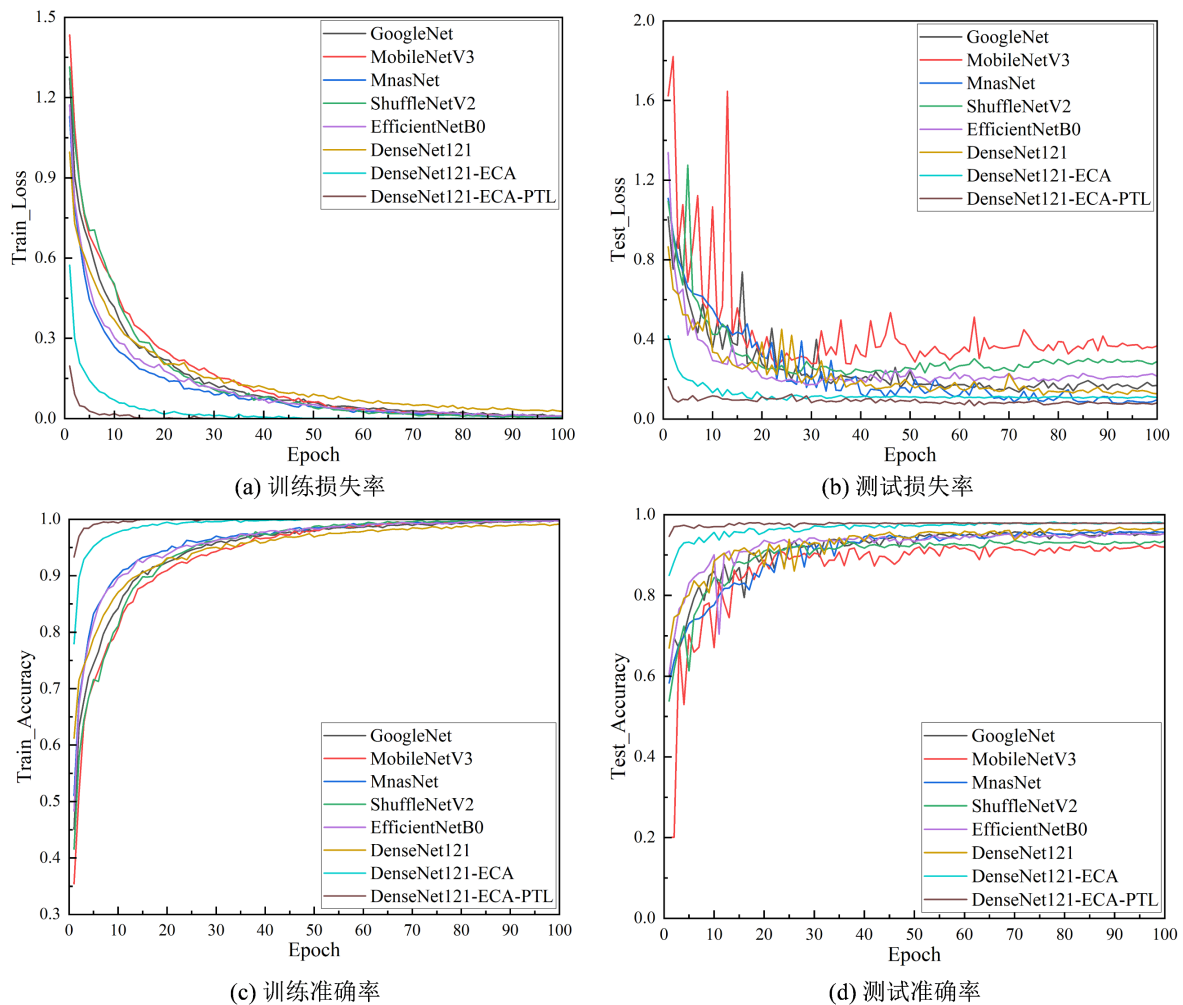


Figure 6. Comparison of training and testing performance curves of different deep learning models on damaged membrane dataset

图 6. 不同深度学习模型在损伤膜面数据集下的训练与测试性能曲线对比

由图 6 可以发现, 本文改进模型展现出显著收敛优势和强大的微小特征学习能力。在 10 个 epoch 时, 训练损失率曲线已经开始收敛并接近于 0, 训练准确率也已经趋于收敛并稳定趋近于 1。同时, 测试损失率曲线迅速收敛至 0.1 区域, 测试准确率也快速稳定在 0.98 以上。相比之下, MobileNet、ShuffleNet 等六种传统主流分类模型受膜面噪声干扰较大, 仅使用常规卷积核和池化核难以充分提取微小损伤的关键特征, 学习能力受限。此类模型收敛缓慢, 经历近 50 个 epoch 计算后, 模型的训练和测试损失率和准确率曲线才趋于收敛, 模型损失率和准确率均没有本文提出的改进模型性能优越。

4.3.2. 改进模型分类推理时间对比

为了对比研究本文提出的改进 DenseNet121-ECA-PTL 模型对采样 100、300、500、1000、5000 和 8000 六种不同预测量级样本的单样本预测时间，选取 DenseNet121 基础模型作为参考，两种模型单样本预测时间对比如图 7 和表 2 所示。可以发现，传统 DenseNet121 在遇到采样样本中噪声较大的图像数据时会发生推理时间急剧增长的现象，随着采样样本的量级增加，这种现象会不定期多次出现，这也拉高了模型总体预测推理时间，平均预测推理时间最长达到了 0.16 s。相比于 DenseNet121 基础模型，本文提出的改进 DenseNet121-ECA-PTL 模型在六种不同采样样本量级的情况下，依然能够非常快速的保持稳定、高效的不同损伤膜面预测推理分类，平均每张图片的预测时间只用了 0.04 s，这也表明本文提出的改进 DenseNet121-ECA-PTL 模型便于后续落地实时检测部署。

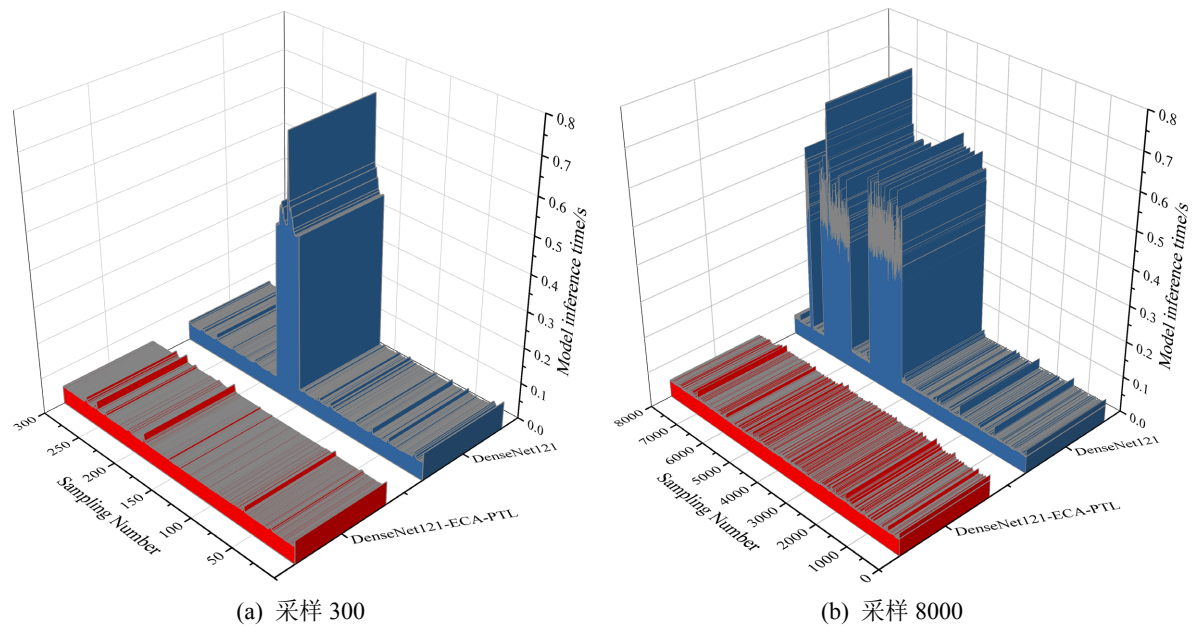


Figure 7. Sample prediction time comparison of the improved model with different sampling sizes
图 7. 不同采样数量下的改进模型样本预测时间对比图

Table 2. Prediction time comparison of the improved model under different sampling quantity conditions
表 2. 不同采样数量条件下改进模型的预测时间对比

采样数量	DenseNet121	DenseNet121-ECA-PTL
100	0.1264	0.0488
300	0.0927	0.0491
500	0.2972	0.0476
1000	0.1677	0.0490
5000	0.0766	0.0472
8000	0.1552	0.0481

为直观展示改进模型对不同损伤类别的识别效果，本文选取改进模型在采样 300 和 8000 两种采样量级下的预测混淆矩阵，如图 8 所示。图中纵轴代表损伤类型的真实标签，横轴代表模型预测的分类结果，对角线上的数值表示预测正确的样本数量。

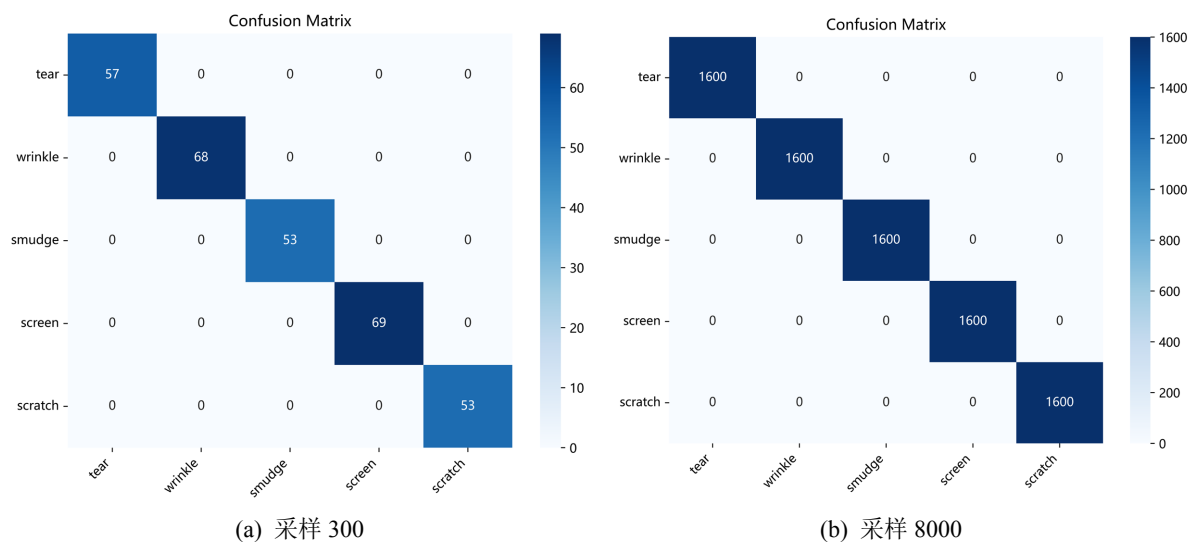


Figure 8. Confusion matrix comparison of the improved DenseNet121-ECA-PTL model under different sampling conditions
图 8. 不同采样条件下改进 DenseNet121-ECA-PTL 模型混淆矩阵对比

由图 8 可以发现，混淆矩阵的非零元素完全集中在主对角线上，且对角线颜色饱和度随样本量增加显著提升。这表明模型对于五类损伤均具有极高的判别精度，误报与漏报现象极不明显。此外，即使在样本量级大幅跨越的情况下，模型依然保持了极佳的性能一致性，表明 ECA 注意力机制能够有效捕获张拉膜面损伤的判别性特征。

为全面评价改进模型的可靠性，本文选取精准率、召回率、F1 值以及马修斯相关系数四项指标，对 DenseNet121 基础模型与 DenseNet121-ECA-TL 改进模型进行对比分析，如图 9 所示。

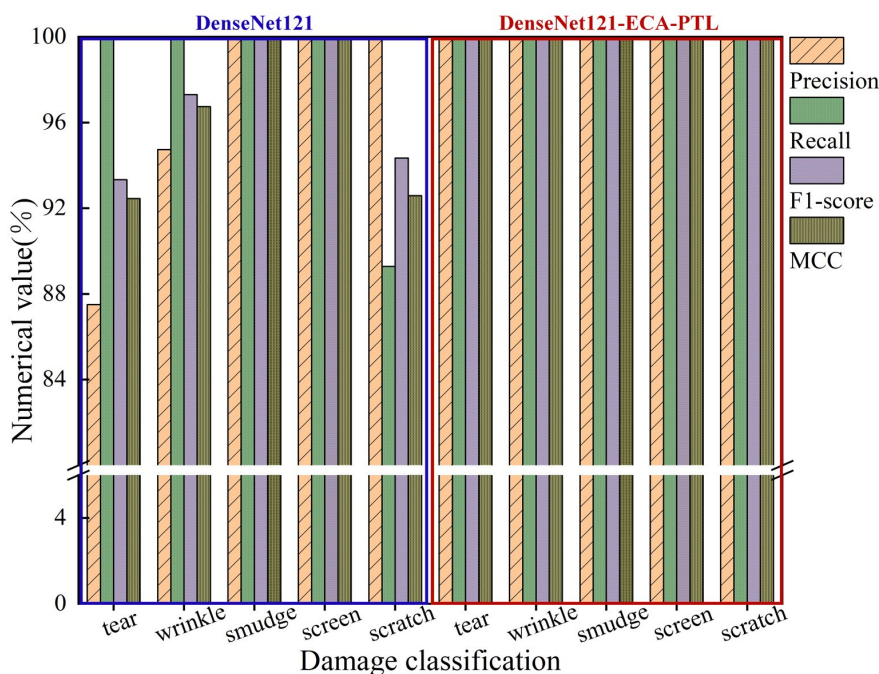


Figure 9. Performance comparison of different evaluation indicators between basic Densenet-121 model and the improved DenseNet121-ECA-PTL model
图 9. Densenet-121 基础模型与 DenseNet121-ECA-PTL 改进模型不同评价指标效能对比

由图9可以发现,除污渍和遮挡物这类明显损伤之外,DenseNet121基础模型在不同损伤类别上的表现存在显著波动,显著弱于改进模型,其中撕裂损伤的准确率仅87%,划损损伤的召回率仅89%,说明传统网络在区分微小损伤与复杂背景噪声时存在局限性。相比之下,本文提出的改进模型在五种典型损伤类别上的各项指标均稳定在98%以上,展现出极高的分类精度与预测一致性。充分表明引入ECA注意力机制后,网络能更精准地提取膜面损伤的关键特征,有效克服了传统模型在特定损伤类型上识别率偏低的问题,证明了改进模型在复杂环境下的鲁棒性与泛化能力。

5. 结论

为了解决张拉膜结构在复杂环境下损伤特征提取难、人工识别效率低的问题,本文提出了基于高效通道注意力机制和迁移学习结合改进的DenseNet121-ECA-PTL模型框架。改进DenseNet121-ECA-PTL模型最终对5种典型膜面损伤类别的识别准确率达到98%,单张图像推理速度仅为0.04s,表明模型在保持高精度的同时,也展现出极佳的轻量化特性与实时性。该算法兼顾了识别精度与计算效率,便于后续部署于移动终端巡检系统,在张拉膜结构智能监测领域具有一定的应用价值。

基金项目

中央高校基本科研业务费专项资金:基于振动-视觉双模态数据驱动膜结构损伤智能检测研究(2025QN1161);国家级大学生创新训练计划项目:基于深度学习的张拉膜结构膜面损伤在线监测系统研究(202410290019Z)。

参考文献

- [1] 王金来,水金锋,刘楠,孙明川,陈一,王金鑫,李东方,乔达.大连梭鱼湾专业足球场罩棚膜结构设计[J].建筑结构,2024,54(16):100-106.
- [2] 袁野,张其林,罗晓群,顾锐杰,黄永. Stfe膜材力学试验与材料本构研究[J].土木工程学报,2024,57(10):11-24.
- [3] 尚旭强,唐蕾,黄天立,王亚飞.基于振动监测数据的大跨斜拉桥实时索力识别[J].铁道科学与工程学报,2025,22(7):3303-3313.
- [4] 黄人玲.基于小波变换-改进粒子群算法的结构损伤识别方法识别研究[J].土木工程,2025,14(6):1394-1402.
- [5] 李冲.基于CNN-GRU网络的无砟轨道路基沉降智能识别[J].土木工程,2025,14(5):1094-1105.
- [6] Ritzy, R., V.A., U., Girija, K. and Rajan, R. (2025) Binary-Class Concrete Surface Crack Detection Using a Transfer Learning Model. *Knowledge-Based Systems*, **324**, Article 113953. <https://doi.org/10.1016/j.knosys.2025.113953>
- [7] Bouguettaya, A. and Zazour, H. (2024) CNN-Based Hot-Rolled Steel Strip Surface Defects Classification: A Comparative Study between Different Pre-Trained CNN Models. *The International Journal of Advanced Manufacturing Technology*, **132**, 399-419. <https://doi.org/10.1007/s00170-024-13341-0>
- [8] Gadiraju, D.S., Azam, S.E. and Khazanchi, D. (2025) SHM-Traffic: DRL and Transfer Learning Based UAV Control for Structural Health Monitoring of Bridges with Traffic. *IEEE Access*, **13**, 6166-6179. <https://doi.org/10.1109/access.2025.3526193>
- [9] Sarhadi, A., Ravanshadnia, M., Monirabbasi, A. and Ghanbari, M. (2024) Optimizing Concrete Crack Detection: An Attention-Based SWIN U-Net Approach. *IEEE Access*, **12**, 77575-77585. <https://doi.org/10.1109/access.2024.3403389>
- [10] Huang, G., Liu, Z., Van Der Maaten, L. and Weinberger, K.Q. (2017) Densely Connected Convolutional Networks. 2017 *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Honolulu, 21-26 July 2017, 2261-2269.
- [11] Hu, X. and Lin, S. (2024) DFFNet: A Lightweight Approach for Efficient Feature-Optimized Fusion in Steel Strip Surface Defect Detection. *Complex & Intelligent Systems*, **10**, 6705-6723. <https://doi.org/10.1007/s40747-024-01512-1>
- [12] Yuan, H., Jin, T. and Ye, X. (2023) Modification and Evaluation of Attention-Based Deep Neural Network for Structural Crack Detection. *Sensors*, **23**, Article 6295. <https://doi.org/10.3390/s23146295>