

基于 ResNet 模型的飞机蒙皮坑洞及发动机内窥镜图像坑洞检测模型研究

张成博 陈胤全

上海工程技术大学飞行学院, 中国·上海 201620

摘要: 为提升飞机维护与安全检查效率, 本文开发了一种基于深度学习的飞机蒙皮坑洞检测模型。该模型以预训练 ResNet 为基础架构, 运用迁移学习方法进行微调, 并设计定制化分类头以适配小坑、中坑、大坑的多标签分类任务。实验结果表明, 模型在验证集上准确率达 80%-85%, 收敛性良好, 虽存在一定过拟合现象, 但整体能有效实现飞机蒙皮坑洞自动识别, 为飞机维护工作提供技术支持。

关键词: 飞机蒙皮检测; 深度学习; ResNet 模型; 迁移学习; 多标签分类

Research on the Detection Model of Aircraft Skin Pits and Engine Endoscope Image Pits Based on ResNet Model

Zhang Chengbo, Chen Yinquan

College of Aeronautics, Shanghai University of Engineering Science, China Shanghai 201620

Abstract: To enhance the efficiency of aircraft maintenance and safety inspection, this paper develops a deep learning-based model for detecting dents on aircraft skins. The model is based on the pre-trained ResNet architecture and fine-tuned using transfer learning methods. A customized classification head is designed to adapt to the multi-label classification task of small, medium, and large dents. Experimental results show that the model achieves an accuracy rate of 80% to 85% on the validation set, with good convergence. Although there is some overfitting, it can effectively realize the automatic identification of dents on aircraft skins and provide technical support for aircraft maintenance work.

Keywords: Aircraft skin detection; Deep learning; ResNet model; Transfer learning; Multi-label classification

0 引言

飞机蒙皮作为飞机外部关键结构, 其表面坑洞会影响飞机气动性能与结构安全性, 及时准确检测坑洞对飞机维护至关重要, 飞机发动机各部件蒙皮对飞机安全更是重中之重。传统人工检测方式依赖工作人员经验, 存在效率低、主观性强等问题。随着深度学习在图像识别领域的快速发展, 基于图像识别技术的自动检测方法成为趋势。本研究旨在开发一款高效的飞机蒙皮坑洞检测模型, 实现不同类型坑洞形成磨损磨蚀的自动识别, 助力飞机维护工作智能化升级。

1 相关技术与方法

1.1 基础模型选择

本研究选用 torchvision 提供的预训练 ResNet 模型作为基础架构, 采用 ResNet34。该模型在 ImageNet 数据集上进行预训练, 具备较强的特征提取能力, 其深层网络结构能有效捕捉图像中的细节特征, 为坑洞检测提供良好的特征基础。

同时, 加载 ImageNet 数据集上的预训练权重 (DEFAULT 或 IMAGENET1K_V1), 可充分利用现有知识, 加速模型在坑洞检测任务中的收敛速度。

1.2 迁移学习策略

为平衡模型泛化能力与训练效率, 采用迁移学习策略。冻结 ResNet 模型除 layer4 和 fc 层之外的所有层参数, 仅对模型最后几层进行微调。此策略既能保留预训练模型在通用图像特征提取上的优势, 又能让模型针对飞机蒙皮坑洞检测这一特定任务进行适应性学习, 减少训练参数数量, 降低计算成本。

1.3 定制化分类头设计

替换 ResNet 原有的全连接层 (fc), 设计并使用 EnhancedClassificationHead 作为新的分类头。该分类头包含多个全连接层、BatchNorm1d 层和 Dropout 层。其中, 全连接层增强模型对复杂特征的拟合能力; BatchNorm1d 层可加速模型训练收敛, 缓解梯度消失问题; Dropout 层通过随机丢弃部分神经元, 减少过拟合风险, 提升模型泛化

性能。分类头最后一层采用 Sigmoid 激活函数, 输出 3 个概率值, 分别对应是否有小坑、中坑、大坑的存在概率, 为了区别于其他类型的磨蚀、缺口等, 满足多标签分类任务需求。

1.4 损失函数选择

由于模型需完成多标签分类任务, 选用 nn.BCELoss (Binary Cross Entropy Loss) 作为损失函数。该损失函数能与 Sigmoid 输出层有效配合, 分别计算每个标签的二分类损失, 准确衡量模型预测结果与真实标签之间的差异, 引导模型优化参数。

2 数据处理与增强

2.1 数据加载

实验数据集由作者采集与整理, 包括与航空公司合作取得、网上经典损伤图片等。主要包含四类样本: 低压涡轮段损伤, 叶片损伤, 叶片材料缺失, 高压涡轮置环损伤, 共约 800 张图像 (见图 1)。




图1 损伤图片加载并进行标注

修改样本尺寸统一为 224×224 像素, 部分图片通过内窥镜拍摄。

构建 AircraftDataset 类负责数据加载工作, 该类可读取飞机蒙皮图像文件和对应的 JSON 标注文件, 从标注文件中提取坑洞标签 (flags), 并将其转换为 one-hot 形式的张量, 为模型训练提供标准化的输入数据 (见图 2)。

```
# 创建运行目录
run_dir = create_run_dir(project_root / args.run_dir)
print(f"运行目录: {run_dir}")

# 创建TensorBoard日志
writer = SummaryWriter(run_dir)

# 设置设备
device = get_device(args.device)
print(f"使用设备: {device}")

# 获取数据转换
transform_train = get_train_transforms(args.img_size)
transform_val = get_val_transforms(args.img_size)

# 构建完整路径
json_dir = project_root / args.json_dir
img_dir = project_root / args.img_dir

# 确保数据目录存在
if not json_dir.exists():
    raise FileNotFoundError(f"找不到JSON标注文件目录: {json_dir}")
if not img_dir.exists():
    raise FileNotFoundError(f"找不到图像文件目录: {img_dir}")
```

获取数据加载器

```
train_loader, val_loader = get_data_loaders(
    json_dir,
    img_dir,
    transform_train,
    transform_val,
    batch_size=args.batch_size,
    val_split=args.val_split,
    num_workers=args.num_workers,
    drop_last=True # 丢弃最后一个不完整的批次
)
```

图2 创建运行目录、数据转换、获取数据加载器、数据校验

2.2 数据集划分

利用 get_data_loaders 函数对完整数据集进行划分, 采用 random_split 方法按 80/20 的默认比例将数据集分为训练集和验证集。训练集用于模型参数学习, 验证集用于评估模型性能, 确保模型在未见过的数据上具有良好的泛化能力。

2.3 数据增强与预处理

训练集增强: 为提升模型泛化能力, 对训练集图像应用多种数据增强技术, 包括 RandomResizedCrop、RandomHorizontalFlip、RandomVerticalFlip、RandomRotation、ColorJitter (调整亮度、对比度、饱和度) 以及 RandomAffine (平移)。这些操作可增加训练数据的多样性, 减少模型对特定图像特征的依赖, 降低过拟合风险 (见图 3)。

- 训练集增强: 应用了多种数据增强技术以提高模型的泛化能力, 包括:
 - RandomResizedCrop
 - RandomHorizontalFlip, RandomVerticalFlip
 - RandomRotation
 - ColorJitter (亮度、对比度、饱和度)
 - RandomAffine (平移)

图3 训练集增强

验证集处理: 仅对验证集图像进行必要的尺寸调整 (Resize、CenterCrop) 和标准化处理, 避免数据增强操作对验证结果产生干扰, 确保评估过程的一致性和准确性。

标准化处理: 无论是训练集还是验证集, 均使用 ImageNet 数据集的标准均值和标准差进行标准化, 将图像像素值转换为符合模型训练要求的范围, 消除不同图像像素值差异对模型训练的影响。

3 模型训练过程

模拟训练过程如图 4 所示。

```
with torch.no_grad():
    progress_bar = tqdm(val_loader, desc='Validating')

    for batch_idx, (inputs, targets) in enumerate(progress_bar):
        # 移动数据到设备
        inputs, targets = inputs.to(device), targets.to(device)

        # 前向传播
        outputs = model(inputs)
        loss = criterion(outputs, targets)

        # 统计信息
        running_loss += loss.item()

        # 计算准确率
        preds = (outputs > 0.5).float()
        correct += (preds == targets).all(dim=1).sum().item()
        total += targets.size(0)

        # 更新进度条
        progress_bar.set_postfix({
            'loss': running_loss / (batch_idx + 1),
            'acc': 100. * correct / total
        })
```

图4 模拟训练过程

3.1 优化器与学习率调度

优化器：选用 AdamW 优化器，该优化器在 Adam 优化器基础上加入权重衰减（weight_decay），能有效缓解过拟合，提升模型泛化能力。通过设置合适的学习率（lr）和权重衰减系数，平衡模型训练速度与收敛效果。

学习率调度：采用 ReduceLROnPlateau 策略调整学习率。当验证损失（val_loss）在设定轮数（patience）内不再下降时，学习率自动乘以一个衰减因子（factor），实现学习率的动态调整。此策略可在训练前期保证模型快速收敛，在训练后期通过降低学习率，使模型更精细地调整参数，进一步优化性能（见图 5）。

```
for batch_idx, (inputs, targets) in enumerate(progress_bar):
    # 移动数据到设备
    inputs, targets = inputs.to(device), targets.to(device)

    # 梯度清零
    optimizer.zero_grad()

    # 前向传播
    outputs = model(inputs)
    loss = criterion(outputs, targets)

    # 反向传播与优化
    loss.backward()
    optimizer.step()

    # 统计信息
    running_loss += loss.item()

    # 计算准确率（对于多标签问题，预测为0.5以上的视为正例）
    preds = (outputs > 0.5).float()
    correct += (preds == targets).all(dim=1).sum().item()
    total += targets.size(0)

    # 更新进度条
    progress_bar.set_postfix({
        'loss': running_loss / (batch_idx + 1),
        'acc': 100. * correct / total
    })
```

图5 优化与学习调度

3.2 设备支持与批处理

设备支持：开发 get_device 函数，实现计算设备的自动选择，支持在 MPS（Apple Silicon GPU）、CUDA GPU 或 CPU 上进行训练。根据运行环境的硬件配置，自动选用最优计算设备，提升模型训练速度。

批处理设置：使用 DataLoader 进行批处理训练。训练加载器设置 shuffle=True，打乱训练数据顺序，避免模型学习数据顺序相关的无关特征；同时设置 drop_last=True，丢弃最后一个不完整的批次，防止因批次大小不一致导致 BatchNorm 层计算错误。验证加载器设置 shuffle=False，保持数据顺序稳定，便于评估模型性能；drop_last=False，充分利用所有验证数据，确保评估结果的可靠性。

3.3 日志与监控

借助 tqdm 库显示训练和验证过程的进度条，方便实时查看训练进展。

利用 torch.utils.tensorboard.SummaryWriter 将训练损失、验证损失、训练准确率、验证准确率以及学习率等关键指标记录到 TensorBoard，通过可视化界面直观监控模型训练过程，及时发现训练中的问题。


在每个 epoch 结束后，打印训练损失、验证损失、训练准确率、验证准确率等关键指标，便于快速了解模型当前性能。

3.4 检查点保存

在每个 epoch 结束后，保存模型的状态字典、优化器状态以及当前训练指标，为后续模型恢复训练或性能分析提供数据支持。同时，保存一个 best_model.pth.tar 文件，记录验证损失最低时的模型状态，确保能获取性能最优的模型，用于后续的测试和实际应用。

3.5 结果可视化

训练结束后，调用 plot_metrics 函数绘制训练 / 验证损失曲线图和训练 / 验证准确率曲线图（保存为 metrics.png），并将图像保存到指定的运行目录。通过可视化图表，直观分析模型的收敛过程、性能变化以及过拟合情况，为模型改进提供依据（见图 6）。






图6 可视化结果-准确率

经过小样本增强,效果明显提升,准确率大幅提高。

4 实验结果与分析

4.1 模型收敛性分析

从 metrics.png 曲线图可以看出,模型具有良好的收敛趋势。在训练初期,训练损失和验证损失均快速下降,同时训练准确率和验证准确率快速上升,表明模型能够快速学习飞机蒙皮坑洞数据中的特征模式,训练过程有效。

4.2 模型性能评估

训练集性能:训练准确率最终接近 100%,训练损失下降到约 0.1 的较低水平,说明模型在训练集上能够准确识别各类坑洞,对训练数据的拟合效果良好。

验证集性能:验证准确率达到 80%–85% 的水平,并在训练中后期趋于稳定;验证损失在 0.25–0.3 之间波动,表明模型在未见过的验证数据上具有一定的泛化能力,能较好地完成任务,但与训练集性能相比存在一定差距。

4.3 训练稳定性分析

整体来看,模型训练过程较为稳定。在训练后期,由于验证损失趋于平稳,学习率调度策略 (ReduceLROnPlateau) 可能触发学习率降低,使模型参数调整更加精细,有效避免了训练过程中的大幅波动,保证了训练的稳定性。

5 结语

5.1 研究结论

本研究成功构建了基于深度学习的飞机蒙皮坑洞多标

签分类模型。通过采用预训练 ResNet 模型、迁移学习策略、定制化分类头以及有效的数据增强方法,模型在验证集上取得 80%–85% 的准确率,且训练过程稳定,收敛性良好。该模型能够自动识别飞机蒙皮上的小坑、中坑和大坑,为飞机维护和安全检查工作提供了有效的技术支撑,有助于提高飞机维护效率和安全性。

5.2 未来展望

尽管模型取得了一定的检测效果,但仍存在过拟合问题,且验证准确率有提升空间。未来可从以下方面进行改进:

增加数据集规模,收集更多不同场景、不同光照条件下的飞机蒙皮坑洞图像,丰富数据多样性,缓解过拟合问题。

探索更先进的模型架构,如 Transformer-based 模型,结合其强大的全局特征捕捉能力,进一步提升模型的特征提取和坑洞识别性能。

优化数据增强策略,引入更多新型数据增强方法,如 MixUp、CutMix 等,增强模型对复杂数据的适应能力。

参考文献:

- [1] Anurag Upadhyay, Jun Li, Steve King and Sri Addepalli. A Deep-Learning-Based Approach for Aircraft Engine Defect Detection[J],Mechines,2023.11,192.
 - [2] 单腾飞. 基于深度学习的飞机蒙皮损伤智能检测方法[J]. 硕士电子期刊出版信息, 2025.10.16.
 - [3] 卢海军, 胡增林. 飞机蒙皮损伤智能检测方法[J]. 基础科学, 2024,09.
 - [4] 裴广达. 孔探与现代航空发动机维护[J]. 航空工程与维修, 2000(05).
 - [5] 李华, 陈果, 陈新波等. 航空发动机内部裂纹自动测量方法研究[J]. 计算机工程与应用, 2016.11.
 - [6] 刘笃喜, 温立民, 朱名铨. 飞机发动机叶片裂纹自适应检测算法的研究[J]. 测控技术, 2007.06.
- 作者简介: 张成博 (2005–), 男, 汉族, 安徽省滁州市人, 本科, 研究方向: 飞行器制造工程。
- 共同第一作者简介: 陈胤全 (2006–), 男, 汉族, 浙江省东阳市人, 本科, 研究方向: 飞行器制造工程。