

一种基于智慧视觉的电力线路检测技术

边晓楠, 高继辉*, 赵庆秘, 马芬禹, 高欣然, 闫凌宇

天津农学院工程技术学院, 天津

收稿日期: 2026年3月11日; 录用日期: 2026年6月4日; 发布日期: 2026年6月16日

摘要

针对电力线路人工巡检效率低、传统图像处理方法泛化能力差的问题, 本文提出一种基于VGG16迁移学习的故障检测方法。首先构建包含绝缘子破损图像数据集, 通过数据增强扩充样本; 然后利用ImageNet预训练的VGG16模型, 采用冻结卷积层、微调全连接层的迁移学习策略, 将通用特征提取能力迁移到电力线路故障识别任务, 最后在自建数据集上进行训练和测试。实验结果表明, 训练损失与验证损失曲线保持同步下降趋势, 无明显过拟合现象。该方法对复杂背景下的故障目标具有较好的识别能力, 验证了迁移学习在小样本电力故障检测中的有效性。

关键词

电力线路, 故障检测, VGG16, 迁移学习

A Power Line Inspection Technology Based on Intelligent Vision

Xiaonan Bian, Jihui Gao*, Qingmi Zhao, Fenyu Ma, Xinran Gao, Lingyu Yan

College of Engineering and Technology, Tianjin Agricultural University, Tianjin

Received: March 11, 2026; accepted: June 4, 2026; published: June 16, 2026

Abstract

Aiming at the problems of low efficiency in manual inspection of power lines and poor generalization ability of traditional image processing methods, this paper proposes a fault detection method based on VGG16 transfer learning. Firstly, a dataset containing insulator damage images is constructed, and the samples are expanded through data augmentation. Then, the pre-trained VGG16 model on ImageNet is utilized, and a transfer learning strategy of freezing the convolutional layers and fine-tuning the fully connected layers is adopted to transfer the general feature extraction

*通讯作者。

文章引用: 边晓楠, 高继辉, 赵庆秘, 马芬禹, 高欣然, 闫凌宇. 一种基于智慧视觉的电力线路检测技术[J]. 电气工程, 2026, 14(2): 39-48. DOI: 10.12677/jee.2026.142004

ability to the power line fault recognition task. Finally, training and testing are conducted on the self-built dataset. The experimental results show that the training loss and validation loss curves maintain a synchronous downward trend, with no obvious overfitting phenomenon. This method has a good recognition ability for fault targets in complex backgrounds, verifying the effectiveness of transfer learning in small-sample power fault detection.

Keywords

Electric Power Circuit, Fault Detection, VGG16, 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

当前, 电力系统故障检测技术正经历深刻演进。一方面, 以继电保护装置为代表的电气量监测体系虽能快速响应短路等典型故障, 但其信息维度单一; 电力系统的线路故障检测实质为二分类问题, 支持向量机主要围绕处理对象进行间隔、对偶核技巧等处理, 能及时、高效寻找出特征空间中的超平面最大间隔分类器, 进而最大化处理正常的的数据与超平面故障数据间隔[1]。

近年来, 随着无人机巡检技术的广泛应用与深度学习算法的快速发展, 基于视觉感知的绝缘子故障智能检测已逐步替代传统人工巡检, 成为电力智能运维领域的研究热点。从早期基于 Faster R-CNN、Cascade R-CNN 的双阶段高精度检测模型, 到以 YOLO 系列为代表的单阶段实时检测算法, 再到无锚框模型与视觉大模型的不断革新, 绝缘子故障检测方法在精度、速度与鲁棒性上实现持续提升; 同时, 面向电力场景的轻量化部署、小样本学习、多模态融合及复杂背景增强等关键技术, 有效解决了故障样本稀缺、小目标缺陷难识别、边缘端算力受限等工程难题, 推动该技术从实验室研究走向工程化落地。

VGG16 作为经典的深度卷积神经网络, 在 ImageNet 等大型数据集上表现出强大的特征表征能力, 其简洁的层叠结构便于理解和改进。本文基于迁移学习思想, 提出一种基于 VGG16 的电力线路故障检测方法。主要工作包括: 构建绝缘子图像数据集, VGG16 的技术解析, 代码编写, 总结分析。实验结果表明, 该方法在绝缘子破损故障检测任务中, 相比传统方法和从头训练的网络, 在准确率和泛化能力上均有显著提升。

本研究的核心意义在于推动电力线路故障检测从依赖人工经验向智能化、自动化模式转型, 填补传统电气量监测在视觉缺陷识别领域的不足。通过深度融合智慧视觉技术与电力设备故障诊断需求, 构建能够精准识别、定位及预警线路故障的智能分析系统, 有效提升故障早期发现的概率与诊断效率。

2. VGG16 技术解析

VGG16 网络是一种简单有效的深度卷积神经网络, 通过使用小卷积核, 并增加网络深度, 可有效提升网络性能[2] [3]。图 1 为详细展开图, 由这张图可以看出, VGG16 的结构包括了输入层、卷积层、池化层和全连接层, 共有 13 个卷积层, 这些卷积层被分为 5 个卷积块, 每个块内有 2~3 个卷积层, 池化层有 5 个, 分别位于每个卷积块之后, 主要用于减少特征图的尺寸。最后是 3 个全连接层, 经过全连接层后输出结果。由此可以看出多个小卷积核代替了大卷积核, 在保证视觉感受不变的情况下, 减小了参数

量，增加了非线性表达能力。

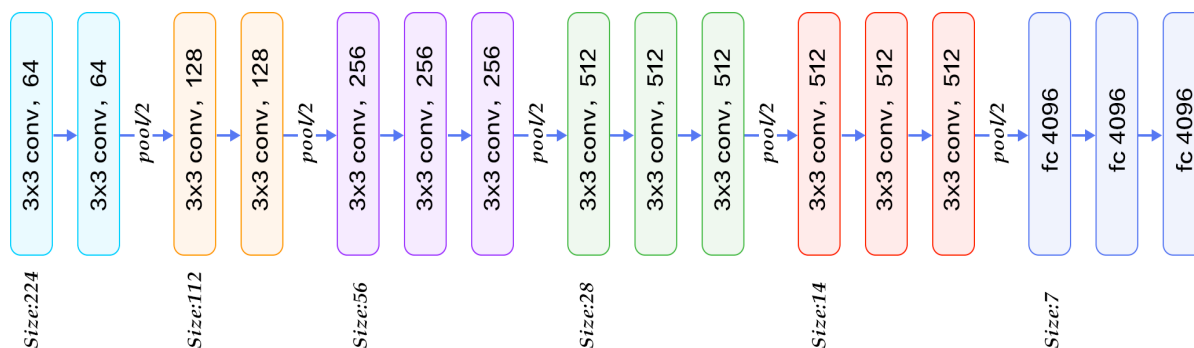


Figure 1. VGG16 expansion diagram

图 1. VGG16 展开图

本研究把 VGG16 作为技术核心，主要基于三个方面，第一个方面指的是浅层特征，网络的前几层(如 conv1_1, conv1_2)能够捕捉绝缘子的边缘、角点、纹理等低级视觉特征。第二个方面是指中层特征，中间层(如 conv3, conv4)可组合低级特征，形成如绝缘子伞裙、螺栓轮廓、防震锤形状等部件级特征。最后一方面就是指高层语义特征，深层网络(如 conv5, fc6, fc7)最终提取出破损绝缘子具有强判别性的高级语义特征。

第二个方面是模型结构的规范性与可迁移性：VGG16 结构规整、模块清晰，在电力领域，由于标注数据获取成本高，通常采用迁移学习策略：在 ImageNet 等超大规模自然图像数据集上预训练的 VGG16 模型，其底层特征提取能力具有通用性。通过微调，仅需用相对少量的绝缘子缺陷样本，调整网络顶层参数，即可得到一个专用的缺陷分类或检测模型，极大地降低了数据需求和训练成本。

第三个方面是分类到检测与分类能力，VGG16 最初是为图像分类设计，但它强大的特征提取能力使其具有三类功能，第一类是缺陷分类，直接使用 VGG16 的全连接层输出，可对裁剪后的绝缘子图像进行“正常类”与“破损类”分类。

3. 数据集的建立

本研究针对电力场景下绝缘子“正常”与“破损”两类状态，构建了专用的图像数据集，为后续基于 VGG16 的目标检测与分类模型训练提供了数据支撑。数据集分为测试集和训练集两个，分别用于对模型的训练和测试。

训练集的建立，训练集用于对模型的训练，一定程度上决定了模型识别的准确性以及模型对特征的学习深度，在设备算力允许的情况下，数据数量要求尽可能的丰富，一类绝缘子至少要有 90 张，训练集的建立分为两部分，第一部分是采集图像，这部分的核心目标是高清晰度以及场景的多样化，绝缘子种类繁多，针式绝缘子，支柱绝缘子，棒式绝缘子，复合绝缘子，钢化玻璃绝缘子，且型号各异，为降低模型学习难度、聚焦于“破损”这一核心特征，本研究在采集时不区分绝缘子的具体类型与型号，仅关注其外观状态，将所有样本统一划分为“正常绝缘子”与“破损绝缘子”两大类。在采集过程中，通过控制拍摄距离、角度与光照条件，确保图像中绝缘子主体清晰、特征突出。同时，为增强数据集的鲁棒性，采集场景覆盖了不同的输电线路环境、天气条件及拍摄距离，使模型能够学习到更具泛化性的特征表示。第二部分是进行数据标注，这也是很关键的一步，数据标注能让模型对绝缘子的图像和状态信息进行统一化处理，提高识别的精确度，本研究采用“人工初标 + 模型辅助审核”的混合标注策略，人工标注是

由人工对采集到的绝缘子图像进行逐帧标注，明确标注出绝缘子的边界框及对应的状态标签(“正常”或“破损”)。模型辅助审核是利用预训练的 VGG16 模型的迁移学习能力，对人工标注结果进行初步校验。通过 VGG16 提取的通用视觉特征，对标注不一致的样本进行二次审核，降低了人工标注的误差率。此外，为进一步提升数据集质量，本研究还引入了多轮审核机制。由多名人员对同一批样本进行交叉标注，并对标注结果进行统计分析，对标注一致性低于阈值的样本进行重新标注，确保了数据集的整体质量。这样我们就完成了训练集的建立。下图中，图 2 为训练集中破损绝缘子的图片，图 3 为训练集中正常绝缘子的图片，图 4 为训练集总库的部分图片。



Figure 2. Training set of damaged insulators
图 2. 训练集破损绝缘子



Figure 3. Training set of normal insulators
图 3. 训练集正常绝缘子

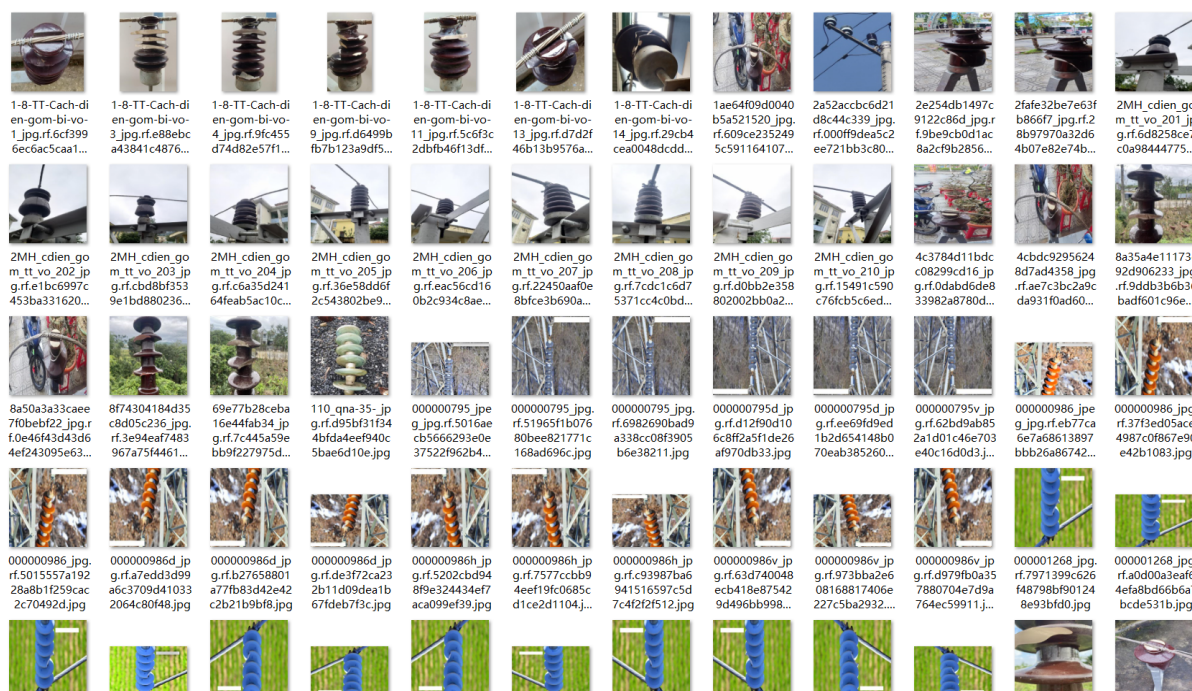


Figure 4. Some training set images
图 4. 部分训练集图片

测试集的建立，同样的测试集仍然分为图像采集和数据标注两部分，测试集的构建是评估模型泛化能力与工程可靠性的关键环节，首先是图像的采集要求和训练集相同，希注意，测试集样本必须与训练集、验证集完全独立，无任何图像重叠，确保评估结果能真实反映模型在未知数据上的性能，另外测试集的数量不需与训练集相当，侧重种类的丰富以及数据的代表性，但测试集类别分布(正常/破损绝缘子比例)、场景特征(光照、角度、背景)需与训练集保持一致，避免因数据分布偏移导致评估失真。接下来是数据标注，与训练集类似，这里不再赘述，必须指出，测试集图像需执行与训练集完全相同的预处理操作，包括尺寸归一化、通道转换、像素值归一化等，确保输入数据格式与模型要求一致。测试阶段不使用任何数据增强操作，以保证评估结果的客观性与可比性，图 5 为测试集中破损绝缘子的图片，图 6 为测试集中正常绝缘子的图片，图 7 为测试集总库部分图片，到此整个数据集完成建立。




Figure 5. Test set with damaged insulator
图 5. 测试集破损绝缘子




Figure 6. Test set with normal insulator
图 6. 测试集正常绝缘子

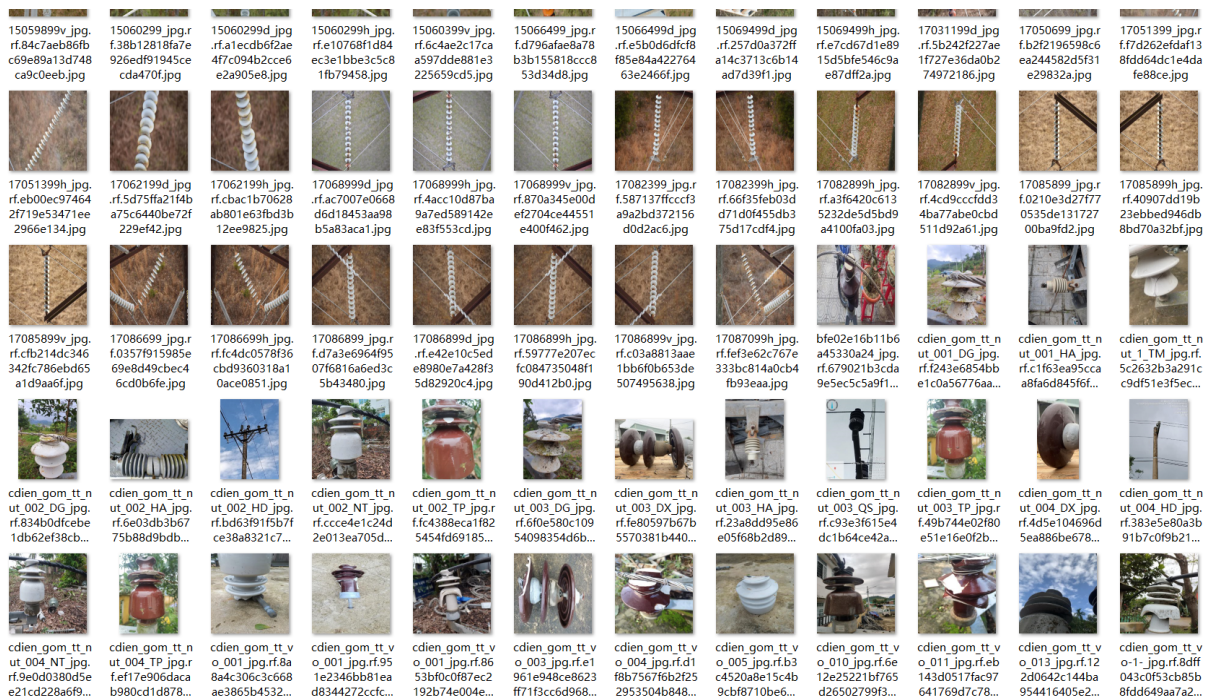


Figure 7. Some test set images
图 7. 部分测试集图片

4. 代码的编写

代码的编写本文将从四个部分来叙述，后文中将展示本文的编写思路以及代码中的关键部分。

第一部分，如图 8，先导入核心组件：从 tensorflow.keras.applications 导入 VGG16：加载预训练的 VGG16 模型，作为特征提取的基础。从 tensorflow.keras.models 导入 Sequential：用于按顺序堆叠模型层，构建自定义网络。从 tensorflow.keras.layers 导入 Dense、Flatten、Dropout、Batch Normalization：用于定义全连接层、特征展平、随机失活和批量归一化，提升模型性能与泛化能力。从 tensorflow.keras.optimizers 导入 Adam：选择 Adam 优化器来更新模型参数。从 tensorflow.keras.callbacks 导入 Early Stopping、ReduceLROnPlateau：设置训练回调，前者用于提前停止训练防止过拟合，后者用于在验证效果停滞时降低学习率。接下来是对数据任务的预处理，先定义测试集和训练集，统一图片尺寸，把图像的像素从 0~255

归一化到 0~1 的区间，加速模型收敛，再把训练集中的 20%划为验证集，接下来是对图片进行二分类任务，`train_datagen` 是数据增强操作，以提升模型泛化能力。接下来是从训练目录 `train_dir` 读取图像，将图像统一缩放到 `IMG_SIZE` 指定的尺寸，这里是对数据的统一化处理。按 `BATCH_SIZE` 批次大小生成数据。`Subset = 'training'`和 `subset = 'validation'`表明 `train_datagen` 启用了 `validation_split` 参数，将训练集自动划分为训练和验证两部分。最后还进行数据增强，目的是当图片旋转、翻转、裁剪、色彩抖动时候，不会影响识别结果。

```
import numpy as np
import matplotlib.pyplot as plt
from tensorflow.keras.preprocessing.image import ImageDataGenerator
from tensorflow.keras.applications import VGG16
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Dense, Flatten, Dropout
from tensorflow.keras.optimizers import Adam
from tensorflow.keras.callbacks import EarlyStopping

# =====
# 1. Set Paths and Parameters
# =====
train_dir = "C:/Users/22331/Desktop/third/train"
test_dir = "C:/Users/22331/Desktop/third/test"
IMG_SIZE = (150, 150)
BATCH_SIZE = 32
```

Figure 8. Import and initialization
图 8. 导入与初始化

第二部分，如图 9，主要是迁移学习与微调，本段为研究的核心部分，首先简单介绍一下什么是迁移学习，迁移学习是机器学习的一种方法，核心是把在过去任务上训练好的模型及其学到的知识，迁移到相关的目标另一个任务中，帮助目标任务快速优化，无需从零训练。它利用任务间的相关性，复用通用特征与模型参数，提升效率与性能，这是应用 VGG16 的核心步骤。其中一种分类是根据技术方面的不同可以分为：(1) 基于样本的迁移学习，其基本思想是，目标样本和源样本有些许不同，但在目标样本中存在部分适合用来训练有效地分类模型，且适应测试数据，该方法适合源数据和目标数据相近的情况；(2) 基于特征的迁移学习，即找到一种好的特征表示最小化源域和目标的不同；(3) 基于参数的迁移学习，源域的参数和目标域的参数有部分相同的；(4) 基于相关性的迁移学习，这种迁移学习中源域和目标域的数据时相关的[4]。本研究采用 VGG16 作为骨干网络构建绝缘子缺陷二分类模型。先加载在 ImageNet 数据集上预训练的 VGG16 模型，移除其顶层全连接层以保留卷积特征提取骨架，仅解冻模型最后 4 层卷积层的参数，其余层保持冻结状态，在 VGG16 卷积骨架后，搭建了自定义的分类头部网络，通过 Flatten 层将卷积输出的多维特征映射展平为一维向量，随后依次堆叠两层全连接层，每层均搭配批归一化和随机失活(Dropout，丢弃率分别为 0.4 和 0.3)操作，以此提升模型特征学习能力并抑制过拟合[5]。分类头的输出层采用单个神经元配合 sigmoid 激活函数，适配绝缘子“正常/破损”的二分类任务需求。模型编译阶段选用 Adam 优化器，设置 $3e-5$ 的低学习率以适配微调训练，损失函数采用二元交叉熵损失，同时将分类准确率作为核心评估指标，完成模型的训练配置。

```

# 4. Build VGG16 Model (Fine-Tuning)
# =====
base_model = VGG16(weights='imagenet', include_top=False, input_shape=(150,150,3))
# Freeze fewer layers to allow more fine-tuning
for layer in base_model.layers[:-4]: # Freeze all layers except last 4
    layer.trainable = False

model = Sequential([
    base_model,
    Flatten(),
    Dense(256, activation='relu'), # Increased from 128 to 256 for more capacity
    BatchNormalization(), # Keep batch normalization for better generalization
    Dropout(0.4), # Adjusted dropout rate for better regularization
    Dense(128, activation='relu'), # Added an extra layer for more depth
    BatchNormalization(),
    Dropout(0.3),
    Dense(1, activation='sigmoid') # Binary classification
])

```

Figure 9. Transfer learning and fine-tuning

图 9. 迁移学习与微调

```

# 第一个子图: 精度曲线
plt.subplot(1, 2, 1)
plt.plot(history.history['accuracy'], label='训练精度')
plt.plot(history.history['val_accuracy'], label='验证精度')
plt.title("模型精度")
plt.xlabel("迭代次数")
plt.ylabel("精度")
plt.legend()

# 第二个子图: 损失曲线
plt.subplot(1, 2, 2)
plt.plot(history.history['loss'], label='训练损失')
plt.plot(history.history['val_loss'], label='验证损失')
plt.title("模型损失")
plt.xlabel("迭代次数")
plt.ylabel("损失值")
plt.legend()

```

Figure 10. Training optimization and curve plotting

图 10. 训练优化与曲线绘制

第三部分, 如图 10, 引入了两种增强型回调函数: 一是早停机制(Early Stopping), 以验证集准确率(val_accuracy)为监控指标, 当连续 patience 个迭代周期性能无提升时自动终止训练, 有效防止过拟合; 二是学习率衰减策略(ReduceLROnPlateau), 以验证集损失(val_loss)为监控指标, 当性能停滞时, 将学习率乘以预设的衰减因子(factor), 帮助模型在后期精细收敛。在训练配置中, 设置最大迭代次数为 40 个 epoch, 同时将上述两种回调函数传入训练流程, 通过数据生成器(train_gen 与 val_gen)动态加载并预处理图像, 模型在训练集上进行参数更新, 并在验证集上评估泛化能力, verbose 参数设为 1 以实时输出训练日志[6]。后续基于训练历史数据绘制了精度与损失变化曲线。首先, 创建尺寸为 12 × 5 英寸的画布, 并将其划分为 1 行 2 列的子图布局, 分别用于展示模型精度与损失的变化趋势。在左侧子图中, 提取并绘制了训练集与验证集的精度曲线, 横轴代表迭代次数, 纵轴为精度值, 通过两条曲线的对比可清晰观察模型在训练过程中的分类能力提升情况; 在右侧子图中, 绘制了训练集与验证集的损失曲线, 用于反映模型预测误差的变化。最后, 通过 tight_layout() 优化子图布局, 避免标签重叠, 并将生成的图表保存为 model_metrics.png 文件, 以便后续分析与展示[7]。

第四部分，如图 11，本模块为绝缘子识别任务的单张图像预测，首先，通过 `load_model` 函数加载已训练完成的绝缘子识别模型，该模型可直接用于对新采集的绝缘子图像进行二分类判断[8]。随后，定义了 `preprocess_image` 预处理函数，该函数将输入图像统一缩放至 150×150 像素的尺寸，转换为 NumPy 数组格式，并通过增加批次维度与像素值归一化操作，将图像数据转换为符合模型输入要求的张量形式。后续使用中可通过指定待检测图像的路径，调用该函数完成数据预处理，再输入模型中进行推理。模块中配置了 `matplotlib` 的后端为 `Agg`，保障可视化功能的兼容性，避免无图形界面环境下的运行错误。

```
# 8. Predict on a Single Image
# =====
import numpy as np
from tensorflow.keras.preprocessing import image
from tensorflow.keras.models import load_model

# 加载保存的模型
loaded_model = load_model('Insulator identification')

# 定义图像预处理函数 - 修正目标尺寸为150x150以匹配模型期望的输入
# 1个用法
def preprocess_image(img_path):
    img = image.load_img(img_path, target_size=(150, 150)) # 修改为150x150以匹配模型输入
    img_array = image.img_to_array(img)
    img_array = np.expand_dims(img_array, axis=0)
    img_array /= 255.0 # 归一化
    return img_array, img
```

Figure 11. Single image prediction
图 11. 单图预测




Figure 12. Training curve
图 12. 训练曲线

5. 分析与总结

本研究构建的基于 VGG16 的绝缘子故障检测模型，其训练过程与收敛特性通过精度 - 损失曲线得到了直观验证，如图 12。

通过对精度 - 损失曲线分析可知，模型在 20 轮迭代过程中，训练精度与验证精度均呈现稳步上升并趋于收敛的态势，最终验证精度稳定在 0.85 以上，表明模型具备优异的特征学习能力；同时，训练损失与验证损失持续下降并最终趋于平稳，且二者差距始终保持在合理范围，证明所采用的策略有效抑制了过拟合现象，确保了模型的泛化性能。实验结果充分说明，迁移学习框架下的 VGG16 模型能够有效挖掘

绝缘子图像的深层语义特征,实现对故障状态的精准判别,训练损失与验证损失曲线保持同步下降趋势,无明显过拟合现象。该方法对复杂背景下的故障目标具有较好的识别能力,验证了迁移学习在小样本电力故障检测中的有效性。

参考文献

- [1] 王建飞, 陈丽霞. 船舶电力系统智能化故障诊断及处理研究[J]. 船舶物资与市场, 2023, 31(3): 96-98.
- [2] 钟武昌, 战洪飞, 林颖俊, 等. 基于 VGG16-SVM-SSA 的产品表面质量检测方法[J]. 计算机集成制造系统, 2024, 30(12): 4435-4445.
- [3] 陈灵方, 张鹏, 李昆, 等. 基于改进 VGG16 网络的小尺寸图像识别研究[J]. 现代信息科技, 2024, 8(23): 105-109.
- [4] 庄福振, 罗平, 何清, 史忠植. 迁移学习研究进展[J]. 软件学报, 2015, 26(1): 26-39.
- [5] 周波. 电力配电网的运行维护及故障排除策略分析[J]. 国际公关, 2019(10): 187.
- [6] 秦占俊. 基于机器视觉的火力发电机组电缆敷设缺陷自动检测方法[J]. 自动化应用, 2025, 66(12): 1-3.
- [7] 陈凤翔, 刘博迪, 方广东. 基于机器视觉的无人机电力巡线技术[J]. 图像与多媒体技术, 2019(4): 60-61.
- [8] 曾昌健, 李丽, 郑为凑. 基于机器视觉的电力线路侦测技术[J]. 海峡科学, 2022(9): 45-49.