

融合纹理特征的输变电边坡土壤轻量化分类^①



姜 岚¹, 安美茹¹, 杭翠翠², 王瑞红³, 秦士立¹

¹(三峡大学 电气与新能源学院, 宜昌 443002)

²(国网湖北省电力有限公司经济技术研究院, 武汉 430077)

³(三峡大学 土木与建筑学院, 宜昌 443002)

通信作者: 姜 岚, E-mail: jl@ctgu.edu.cn

摘 要: 输变电工程中边坡土壤类型的准确识别对稳定性评估与防护设计具有重要意义. 然而, 传统的野外调查与实验室分析效率低下且主观性强, 难以满足复杂工程场景的实时识别需求. 为此, 本文提出一种基于纹理融合的轻量化深度学习模型 SSR-MobileNetV2-T. 该模型采用多尺度 Gabor 滤波、局部二值模式 (local binary pattern, LBP) 的双分支网络结构, 以增强对土壤微观纹理的特征提取能力. 构建了多源土壤图像数据集, 并通过 HSV 阈值分割与多样化数据增强扩充样本, 模拟野外复杂环境条件, 以端到端方式训练模型. 实验结果表明, 在 5 类边坡土壤图像分类任务中, SSR-MobileNetV2-T 模型平均准确率达到 98.1%, *F1-score* 达到 97.9%, 整体性能优于 SVM、CNN 以及 EfficientNet 等典型轻量化模型, 尤其在砾石和砂类别中表现突出. 参数敏感性分析和消融实验验证了各模块设计的有效性. 研究表明, SSR-MobileNetV2-T 模型兼具轻量化与高精度特性, 可为输变电工程中边坡土壤的智能识别提供高效、可靠的技术支撑.

关键词: 纹理特征; 轻量化模型; SSR-MobileNetV2-T 模型; Gabor 滤波; 局部二值模式

引用格式: 姜岚, 安美茹, 杭翠翠, 王瑞红, 秦士立. 融合纹理特征的输变电边坡土壤轻量化分类. 计算机系统应用. <http://www.c-s-a.org.cn/1003-3254/10105.html>

Lightweight Classification for Transmission and Substation Slope Soils Incorporating Texture Features

JIANG Lan¹, AN Mei-Ru¹, HANG Cui-Cui², WANG Rui-Hong³, QIN Shi-Li¹

¹(College of Electrical Engineering & New Energy, China Three Gorges University, Yichang 443002, China)

²(Economic and Technical Research Institute of State Grid Hubei Electric Power Co. Ltd., Wuhan 430077, China)

³(School of Civil Engineering & Architecture, China Three Gorges University, Yichang 443002, China)

Abstract: Accurate identification of slope soil types is vital for stability assessment and protective design in transmission engineering. However, conventional field surveys and laboratory analyses have low efficiency and high subjectivity, thus making them difficult to satisfy the requirements for real-time identification in complex engineering scenarios. To this end, this study proposes a lightweight deep learning model based on texture integration SSR-MobileNetV2-T, which employs a dual-branch network structure combining multi-scale Gabor filtering and local binary pattern (LBP) to enhance the ability to extract soil micro-texture. Meanwhile, a multi-source soil image dataset is constructed, and the samples are enlarged via HSV-based threshold segmentation and diverse data augmentation to simulate complex field conditions and thus train the model in an end-to-end manner. The experiments show that on a five-class slope-soil image classification task, the SSR-MobileNetV2-T model achieves an average accuracy of 98.1% and an *F1-score* of 97.9%, generally outperforming typical lightweight models such as SVM, CNN, and EfficientNet, with prominent performance for gravel

^① 基金项目: 国家自然科学基金面上项目 (51979151)

收稿时间: 2025-09-15; 修改时间: 2025-09-26, 2025-10-14; 采用时间: 2025-10-20; csa 在线出版时间: 2026-01-08

and sandy soils in particular. Parameter sensitivity analysis and ablation experiments confirm the effectiveness of each module's design. The study indicates that SSR-MobileNetV2-T is both lightweight and highly accurate, providing efficient and reliable technical support for the intelligent identification of slope soil in transmission projects.

Key words: texture feature; lightweight model; SSR-MobileNetV2-T model; Gabor filtering; local binary pattern (LBP)

输变电工程施工和维护过程中常因开挖或地形改造形成临时边坡, 这些边坡多分布于山地丘陵等复杂地带, 其稳定性直接关系到输电线路运行安全与电力系统供电可靠性^[1,2]. 土质边坡因结构松散、固结能力弱, 易受降雨渗透与冻融循环影响; 岩质边坡因节理裂隙发育与风化作用, 常出现局部滑塌与剥落^[3]. 据统计, 约 68% 的沿线边坡失稳事故与土壤类型误判导致的防护措施不当直接相关^[4], 其中邻近居民区和交通要道的风险尤为突出. 传统人工检测方法周期长、成本高, 难以满足大规模边坡巡检的时效性要求. 因此, 开发快速、精准的土壤类型识别技术对保障输变电工程边坡稳定和人员安全具有重要意义.

为了对输变电临时边坡的土壤类型进行识别, 国内外研究学者展开了一系列研究. 传统研究方法包括现场物理观测和实验室理化分析^[5,6]方法, 以及支持向量机分类技术^[7]、多分类器集成技术^[8]等机器学习方法. 传统的现场物理观测与实验室理化分析尽管结果可靠, 但存在耗时费力、对测试人员经验依赖大且无法实现大范围快速检测的问题. 早期基于人工特征的机器学习方法在小样本可控场景中有一定效果, 但对复杂野外环境的泛化能力不足. 近年来, 随着数据量和计算能力的提升, 深度学习凭借端到端的特征学习方式在图像识别领域取得显著进展, 并逐步应用于土壤图像分类与属性推断, 显著提高了自动识别的准确率和鲁棒性^[9]. 然而, 常规深度模型的高计算和存储需求限制了其在移动终端或现场设备上的部署, 成为工程现场实时判读的主要障碍.

为在有限的计算与存储资源下兼顾模型精度与效率, 轻量化网络 (如 MobileNet 系列、ShuffleNet 以及 EfficientNet 等) 已成为工程应用场景中的优先选择. ShuffleNet、EfficientNet^[10-12]等网络在通用视觉任务中表现突出, 但其设计更偏向通用图像分类, 对土壤识别中微观纹理与跨尺度结构的建模仍缺乏针对性. 此外, 不同架构在复杂场景下的可扩展性和工程部署的灵活性也存在差异. 综合考虑, MobileNetV2 结构简洁、易

于改造和扩展, 并已在多个移动端任务中得到广泛验证; 其倒残差结构与深度可分离卷积能够在显著降低模型参数量和计算成本的同时保持良好的分类性能, 适用于资源受限的工程现场. 目前已有工作尝试将 MobileNet 变体用于土壤识别并实现移动端部署, 如 Inazumi 等^[13]采用 Soil-MobileNet 的卷积神经网络 (CNN) 模型来对土壤进行分类, 提出的 Soil-MobileNet 模型可用于手机上的实时土壤分类, 在识别准确率较高的基础上实现了在移动端的部署; Banoth 等^[14]将 MobileNetV2 架构与定制的 CNN 模型相结合, 对包含 108 张土壤图像的数据集进行验证, 在计算效率和准确率上均有所提高. 但将此类轻量化主干直接用于边坡土壤识别仍存在若干局限. 首先, 深度可分离卷积与窄通道设计在压缩模型的同时, 常会削弱对图像中高频纹理和方向性细节的表达能力, 而这些细微纹理往往是区分粉土与黏土等细粒土类的关键依据; 其次, 轻量化网络通常采用较小的卷积核和较浅的层次结构, 因而难以在同一模型中既兼顾局部微观细节又反映宏观结构格局, 对含有不同尺度颗粒混合的剖面难以形成全面表征; 同时, 现场采集的土壤图像受光照、湿度和遮挡等条件影响较大, 模型在不同采集条件或跨场景应用时容易出现性能波动.

根据上述背景, 本文设计了一种基于融合纹理的轻量化改进模型 SSR-MobileNetV2-T, 该模型以 MobileNetV2 为主干, 通过增加空间多尺度模块、纹理分支与通道注意力, 增强对细粒纹理及跨尺度结构的表征能力, 从而兼顾模型轻量化与识别精度, 实现工程现场可部署的高效识别.

1 土壤分类、数据集与预处理

1.1 土壤分类

目前, 土壤分类的方法很多, 如按土壤成因划分可分为残积土和运积土 (冲积土、风积土、冰碛土), 按照颗粒粒径分布可分为粗粒土、细粒土和有机质土^[15]. 在输变电工程边坡稳定性分析中, 应根据土壤的力学

性质和工程适用性进行分类. 根据国际通用, 结合颗粒级配和塑性指数 (PI) 将土分为砾石 (G)、砂 (S)、粉土 (M)、黏土 (C)、有机土 (O)^[16], 如图 1 所示. 在本研究中, 将上述 5 类作为识别目标进行模型训练和评估.

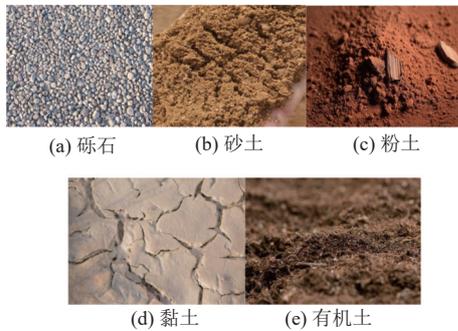


图 1 土壤分类示意图

1.2 数据集的获取与构建

为了构建边坡土壤图像数据集, 本研究使用带 f/2 光圈镜头的 48 MP 智能手机摄像头对野外土壤剖面进行拍摄 (ISOCELL GM2.0 传感器, 具有智能宽动态范围 WDR 技术, 可在高对比度条件下捕获清晰图像). 所选拍摄地点涵盖丘陵、河谷、平地等生态区域, 共采集 506 个不同土壤剖面样本, 涵盖砾石、砂、粉土、黏土和有机土这 5 类. 在野外采集过程中, 尽量保证多样性, 例如在不同光照、湿度和拍摄角度下采集图像, 包含裸露土层和部分植被覆盖等多种场景. 图 2 给出了典型山地区域采集的土壤剖面样本示例, 可见在不同光照条件下土壤表层颜色和纹理的明显差异.



图 2 山地野外采样的土壤剖面示例

同时, 为进一步扩充训练样本, 我们还采用了公开的土壤图像数据集, 包括 Shi 等^[17]开发的 897 张土壤

剖面图像、Gyasi 等^[18]构建的包含 4 864 张土壤图像的 VITSoil 数据集以及 Raihan 等^[19]的 Mendeley 土壤湿度数据集 (包含 1 177 张土壤表面图像). 将本研究采集的野外图像与这些公开数据集结合, 构建了一个包含自然光照、植被干扰、多水分含量等多样条件的大规模土壤图像数据集, 约 7 000 余张土壤样本.

1.3 图像预处理与划分

获取的土壤图像存在背景复杂、数据量不足等问题, 需要对图像进行预处理 (包括归一化、数据增强、背景划分等), 并进行土壤数据集的划分. 首先, 对原始图像进行尺寸归一化和去噪处理, 以满足网络输入要求; 然后, 针对背景复杂问题, 采用 HSV 颜色空间阈值分割方法提取土壤感兴趣区域 (ROI). 最后, 将预处理后的数据集按 8:1:1 比例随机划分为训练集、验证集和测试集, 以便进行模型训练和性能评估. 具体步骤如图 3 所示.

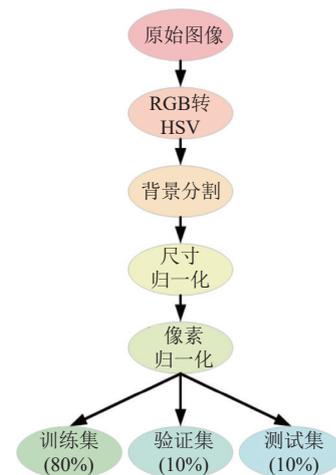


图 3 土壤图像处理与划分

1.3.1 数据增强

在获取原始图像后, 对数据进行了预处理以适应模型训练. 针对野外采样图像可能存在的光照和视角变化, 我们还进行了多种数据增强操作, 包括旋转、裁剪、翻转、缩放和亮度调整等^[20]. 主要增强参数如下: 随机旋转角度范围为 $\pm 30^\circ$ – $\pm 45^\circ$, 以模拟拍摄视角变化; 随机平移比例不超过图像宽高的 0.3; 随机裁剪比例为 0.6–1.0, 以保持目标区域完整; 镜像翻转概率为水平 0.5、垂直 0.2; 缩放因子范围为 0.5–1.2; 亮度调整系数 α 取值范围为 0.6–1.4, 用于模拟晴天、阴天及阴影条件; 随机遮挡 (cutout) 面积占图像的 2%–12%, 概率为

0.3, 用于提升模型对局部缺失的鲁棒性.

这些操作不仅增加样本量, 还模拟了不同光照和湿度条件, 提高模型对变化场景的适应能力. 例如, 通过调整亮度模拟晴天与阴天之间的差异, 通过缩放和

翻转模拟不同拍摄角度. 数据增强后, 训练集规模扩展到 50000 余张, 大幅缓解样本不足问题, 并增强模型的鲁棒性. 以样本中某一张砂图片为例, 其数据增强图像处理的整个过程如图 4 所示.

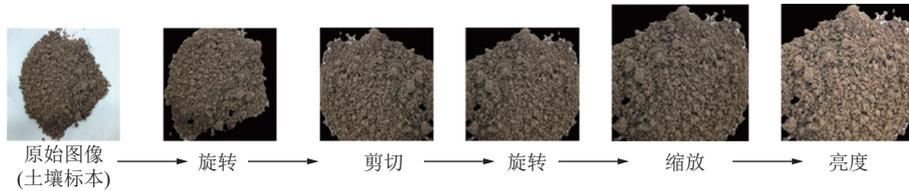


图 4 土壤样本数据增强处理结果

1.3.2 背景分割与 ROI 提取

为进一步提高训练样本的信噪比并减少背景对特征学习的干扰, 对原始拍摄图像进行土壤感兴趣区域 (ROI) 的提取. 为得到便于在移动端现场调试与迁移的样本, 需要满足以下条件: 一是计算代价低、实现简单且无需像素级标注, 便于在样本有限的初期阶段快速构建高质量训练集; 二是 HSV 将色相与亮度分离, 土壤与常见背景 (天空、植被、混凝土等) 在色相/饱和度上通常存在可区分的分布, 基于统计阈值即可显著提升 ROI 的纯度, 从而提高下游轻量化分类器的训练效率与收敛稳定性; 三是该方法具有良好的工程适配性, 阈值可根据现场采样的统计特征快速调整, 便于在不同采集设备或光照条件下现场调试与迁移. 因此本文选择基于 HSV 的阈值分割^[21]方法.

HSV 背景分割的具体步骤: 首先将 RGB 图像转换到 HSV (hue-saturation-value) 色彩空间, 依据训练集像素分布统计确定阈值区间为 $H \in [0.05, 0.35]$, $S \in [0.10, 0.80]$, $V \in [0.20, 0.95]$; 随后生成二值掩模, 采用结构元半径 3 与 7 的形态学开闭运算去噪与填洞; 最后按连通域面积筛选主区域并统一缩放为 224×224 像素输入网络^[22]. 具体流程如图 5 所示.

依据 H 、 S 、 V 分量的阈值设定^[23], 可有效提取土壤区域 (ROI), 并排除复杂背景干扰. 该方法能在不依赖语义标注的前提下, 显著提高土壤区域纯度与特征稳定性, 为后续纹理特征融合提供高质量输入. 图 6 展示了典型土壤样本的采集图像及其对应的 ROI 提取效果.

1.3.3 归一化与数据划分

将预处理后的数据集随机划分为训练集、验证集和测试集. 设总样本数为 N , 按比例划分为 8:1:1, 即 80% 作为训练集, 10% 作为验证集, 10% 作为测试集.

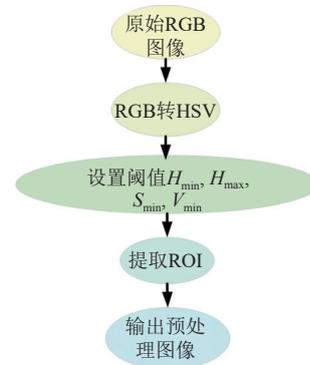


图 5 背景分割与 ROI 提取步骤



图 6 背景分割与 ROI 提取处理

2 基于 SSR-MobileNetV2-T 模型的土壤图像识别算法

2.1 算法设计

2.1.1 算法总体思路

近年来, 随着输变电边坡工程安全监测对土壤类型快速、准确识别需求的不断提升, 传统人工目视鉴别方法在效率与精度方面的不足逐渐显现^[24]. 为了解决上述问题, 本文以轻量级的 MobileNetV2 网络为基础, 提出一种改进的边坡土壤图像识别算法——SSR-MobileNetV2-T 模型, 算法整体结构如图 7 所示.

模型采用双分支网络结构: 主干分支 (SSR-MobileNetV2) 用于提取全局语义特征, 纹理分支 (texture branch)

用于显式增强多尺度纹理特征. 主干分支基于 MobileNetV2 设计, 利用深度可分离卷积减小模型参数量, 并通过空间多尺度模块 (SS 模块) 自适应捕获不同尺度的宏观结构信息. 纹理分支则融合多尺度 Gabor 滤波器和 LBP 算法, 从不同频域和统计纹理角度提取土壤微观纹理特征. 两个分支提取的特征通过通道注意力模块 (CA 模块) 进行融合加权, 进一步抑制背景干扰.

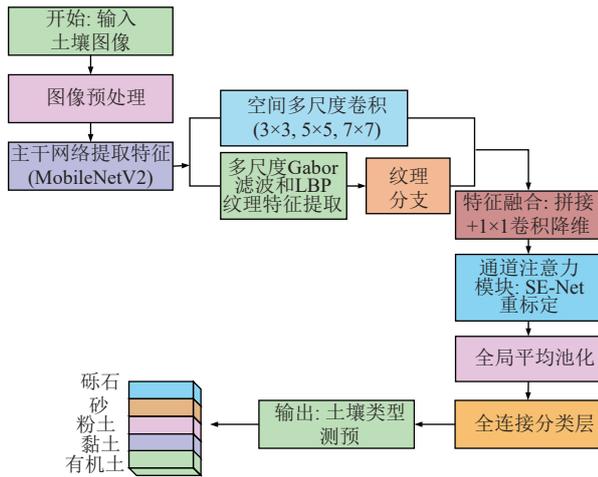


图7 算法流程图

2.1.2 MobileNetV2 主干网络的设计

主干网络为 MobileNetV2, 其采用倒残差结构和深度可分离卷积, 这种设计在保持网络参数精简的同时, 有效提升特征的表达能力, 适合像输变电工程边坡土壤图像识别等资源受限的移动端设备部署. 网络结构由初始卷积层、多个倒残差模块 (inverted residual module) 和全局平均池化层组成.

倒残差模块通过扩张因子 t 对特征进行升维, 再通过逐层深度可分离卷积进行特征提取, 随后通过 1×1 卷积恢复到低维特征空间. 深度可分离卷积和扩张因子提高了网络的非线性特征学习能力, 减少参数量, 提升计算效率, 能有效提取土壤图像的中低层次全局几何特征和基础纹理信息. 具体的结构参数如表 1 所示. 土壤图像深度可分离卷积的倒残差模块如图 8 所示.

2.1.3 空间多尺度模块的设计

为应对边坡土壤图像中砾石、砂土等宏观结构的尺度多样性问题, 本文设计了空间多尺度 (spatial multiscale, SS) 模块. 该模块以前级网络输出的低层特征图为输入, 通过 3 条并行的卷积分支 (核尺寸为 3×3 、膨胀率分别为 2 与 3 的 3×3 卷积分支) 同步进行特征提取. 各分支输出均统一至 256 个特征通道,

随后在通道维度进行拼接与融合, 以实现对不同尺度空间信息的有效整合.

表 1 MobileNetV2 网络结构及参数

Input	Operator	t	c	n	s
224×224×3	Conv2d	—	32	1	2
112×112×32	bottleneck	1	16	1	1
112×112×16	bottleneck	6	24	2	2
56×56×24	bottleneck	6	32	3	2
28×28×32	bottleneck	6	64	4	2
14×14×64	bottleneck	6	96	3	1
14×14×96	bottleneck	6	160	3	2
7×7×160	bottleneck	6	320	1	1
7×7×320	Conv2d 1×1	—	1792	1	1

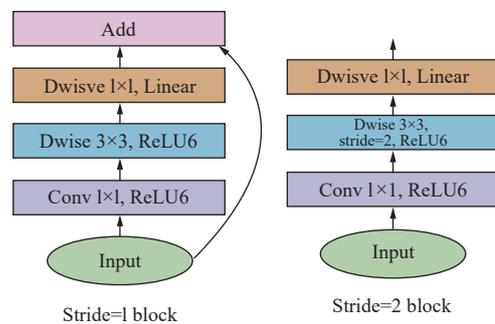


图8 MobileNetV2 倒残差块的结构图

该模块通过整合不同尺度卷积核所提取的特征, 使模型能同时感知土壤剖面中从宏观层理到微观颗粒分布的多层次结构信息. 这种多尺度特征融合策略, 增强了模型对土壤图像中几何形态与结构特征的捕捉能力, 从而能在复杂背景下更可靠地区分不同土壤类型, 并为后续通道注意力模块提供信息更完备的特征图.

2.1.4 通道注意力模块的设计

在多尺度特征提取后, 为进一步增强对土壤图像关键特征通道的识别能力, 同时抑制无关信息与噪声干扰, 本文引入了基于 SE-Net (squeeze-and-excitation network) [25] 的通道注意力 (channel attention, CA) 机制. 该模块首先通过全局平均池化操作对每个特征通道进行“压缩”, 将其转换为一个通道描述符. 随后, 该描述符经由一个两级全连接层 (中间带有降维与还原层) 构成的“激励” (excitation) 结构, 通过 Sigmoid 激活函数生成各通道的归一化权重. 最终, 这些权重被用于对原始特征图进行通道维度的重标定, 实现自适应特征优选.

该模块的引入能够自适应地关注与土壤类型密切相关的关键特征 (如特定矿物质的反光特性、有机质的颜色信息等), 从而显著提升特征表示的质量与模型

的判别能力. 其结构如图 9 所示, 空间多尺度模块与通道注意力模块的串联处理流程如图 10 所示.

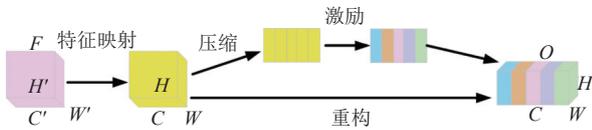


图 9 通道注意力结构

2.1.5 纹理特征提取模块的设计

针对粉土与黏土等类别间微观纹理差异细微、难以区分的问题, 本文设计了一个独立的纹理特征提取模块 (texture feature extraction, T). 与侧重宏观几何结构的空间多尺度模块不同, 本模块专门致力于捕捉土壤表面的微观纹理模式^[26].

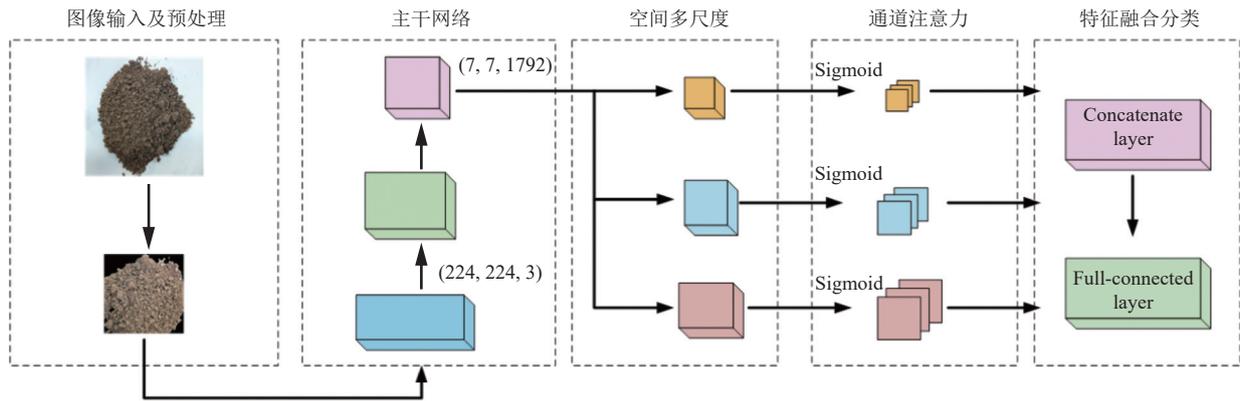


图 10 SSE 模块土壤样本图像处理

在结构设计上, 本模块融合了传统图像处理算子与深度学习方法. 首先, 利用多方向、多尺度的 Gabor 滤波器组 (3×3、5×5、7×7) 对输入图像进行卷积, 以模拟人类视觉系统对纹理方向的敏感性, 从而增强模型对土壤表面方向性纹理 (如流水痕迹、沉积层理) 的响应. 然后, 引入局部二值模式 (LBP) 算子来刻画图像中每个像素点与其邻域的强度关系, 以此捕捉对光照变

化不敏感的局部纹理结构信息. 最后, 将 Gabor 与 LBP 提取的互补性纹理特征进行融合, 并通过轻量级卷积层进行高阶特征映射与维度规整.

该模块显著提升了模型对粉土、黏土和有机土等易混淆类别的识别精度, 能够有效鉴别土壤表面的光滑度、颗粒感和微裂纹等细微特征, 为最终分类提供重要的判别依据. 纹理特征提取的具体流程如图 11 所示.

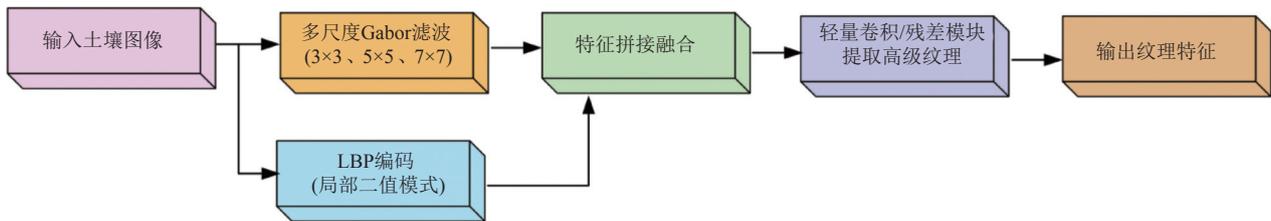


图 11 纹理特征提取流程

纹理特征提取模块通过纹理分支, 采用深度可分离卷积与轻量级残差模块, 确保低计算量下提取高质量的纹理特征. 不同土壤纹理特征提取流程及可视化结果如图 12 所示.

2.2 特征融合与模型训练

算法采用“双分支”特征融合方式, 将主干网络提取的高层全局特征与纹理模块提取的局部纹理特征进

行通道维度拼接, 通过 1×1 卷积进行降维融合, 以获得对土壤图像的整体与局部特征全面表达.

训练策略上, 首先对主干网络和纹理模块进行预训练, 随后联合进行微调训练. 同时, 选取 Adam 优化器进行参数更新, 并通过 INT8 量化压缩技术降低模型的部署存储开销, 确保算法能高效部署在现场的移动端设备中.

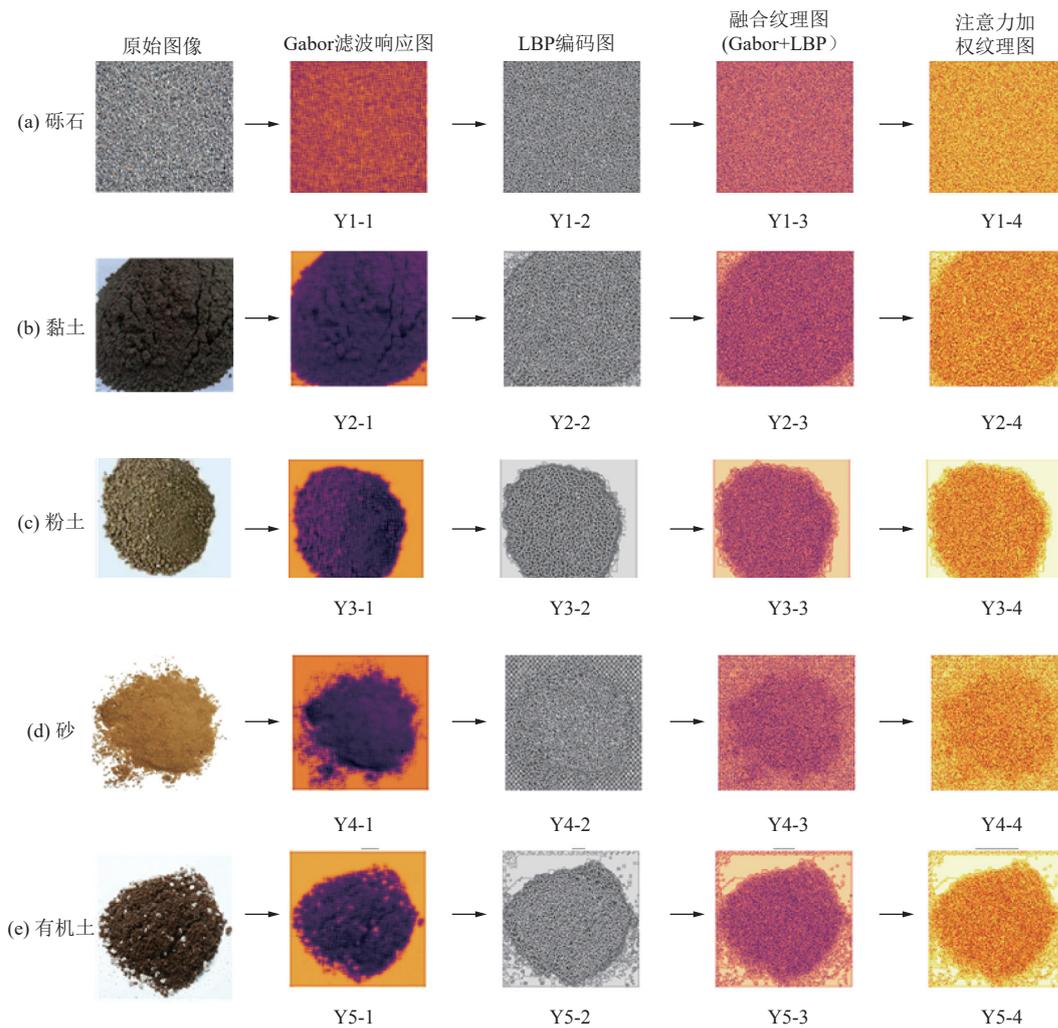


图 12 纹理特征提取流程及可视化结果

2.3 算法实现流程及可行性分析

算法通过对每个模块的输入输出特征尺寸、通道维度进行严格控制与匹配,保证了整体结构在实际实现中的可行性.同时,通过对土壤图像的中间特征响应图的可视化分析,如图 13 所示,进一步验证了模块设计的合理性与有效性.

从图 13 中可以看出,随着网络逐层深入,特征图逐渐从底层边缘信息(图 13(a)的 Y1-1-Y1-4)过渡到显著纹理增强区域(图 13(c)的 Y3-1-Y3-4、图 13(d)的 Y4-1-Y4-4),为分类器提供了丰富的判别依据.该模块设计显著提升模型在复杂背景下对细粒土与粗粒土的识别能力,同时保持结构轻量,适用于边坡土壤的现场快速识别.

2.4 评价指标

考虑到土壤图像数据集中各类别样本数量不均衡,

本研究采用准确率 (*Accuracy*)、精确率 (*Precision*)、召回率 (*Recall*)、*F1* 分数 (*F1-score*) 以及混淆矩阵作为性能评估指标,以综合评价模型的性能与泛化能力.准确率、精确率、召回率和 *F1* 分数指标的计算公式如式 (1)-式 (4) 所示:

$$Accuracy = \frac{TP+TN}{TP+FP+TN+FN} \times 100\% \quad (1)$$

$$Precision = \frac{TP}{TP+FP} \times 100\% \quad (2)$$

$$Recall = \frac{TP}{TP+FN} \times 100\% \quad (3)$$

$$F1-score = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (4)$$

其中, *TP* (true positive) 是模型正确预测为正类的样本数; *TN* (true negative) 是模型正确预测为负类的样本数 (多分类中一般不单独计算); *FP* (false positive) 是模

型错误预测为正类的样本数; FN (false negative) 是模型错误预测为负类的样本数.

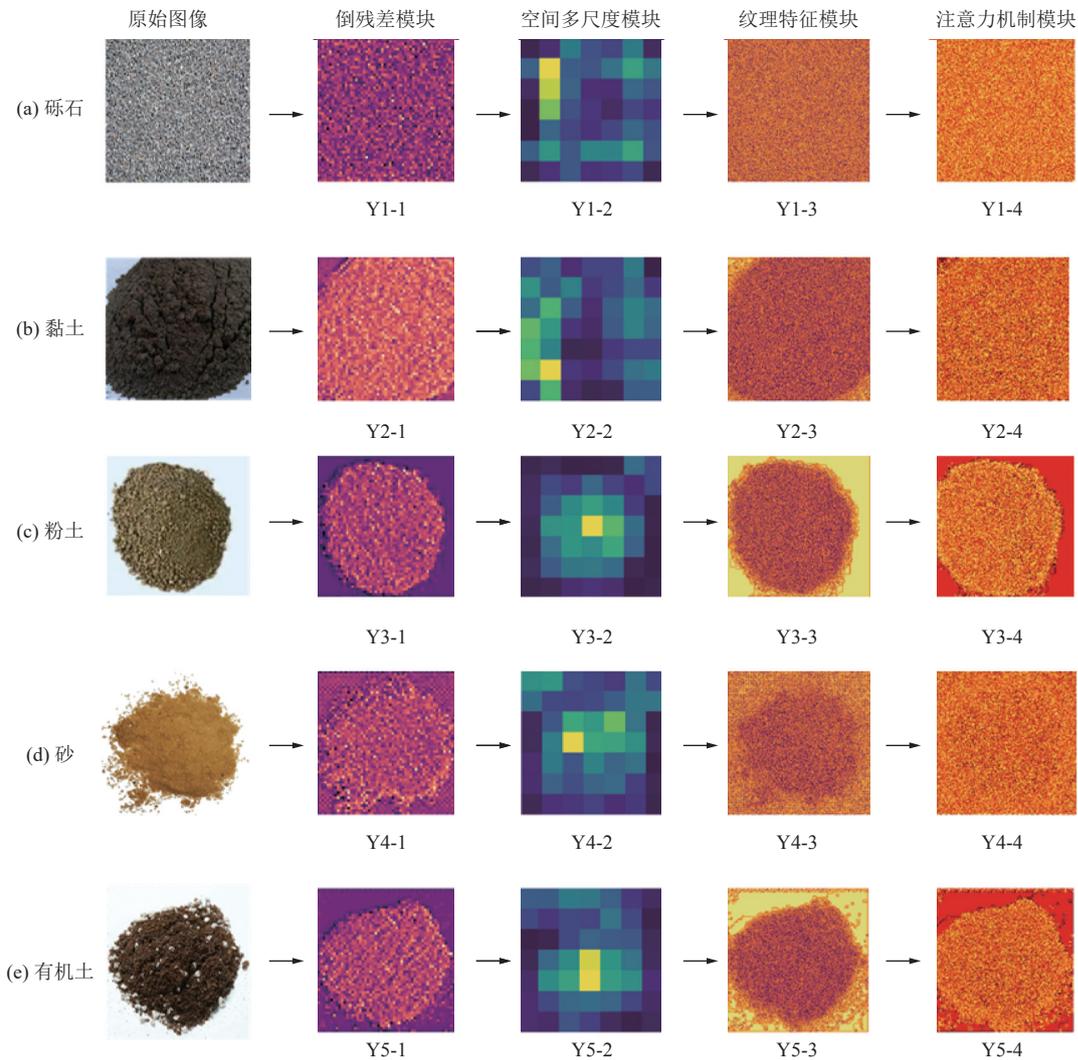


图 13 SSR-MobileNetV2-T 特征提取流程

3 实验结果与分析

3.1 消融实验

实验在配备 NVIDIA RTX 4060 GPU 的工作站上进行, 使用 PyTorch 深度学习框架. 模型训练采用 Adam 优化器, 初始学习率设置为 $1E-3$, 并应用余弦退火策略进行学习率衰减, 批量大小 (batch size) 为 32, 共训练 100 个轮次 epoch. 损失函数为交叉熵损失.

本文建立的 SSR-MobileNetV2-T 边坡土壤图像识别算法, 是在 MobileNetV2 主干结构基础上融合多分支、纹理增强与注意力机制等模块的改进模型. 为系统评估各模块对整体性能的贡献, 本文设计并实施了消融实验. 消融实验通过逐步去除或替换模型中的关键组件, 分析不同模块对分类精度的影响. 具体实验设

置如下.

- (1) Baseline: 仅包含标准的 MobileNetV2 主干网络;
 - (2) Baseline+SS: 在 Baseline 基础上增加空间多尺度 (SS) 模块;
 - (3) Baseline+SS+CA: 在上一配置基础上增加通道注意力 (CA) 模块;
 - (4) Baseline+T (Gabor): 在 Baseline 基础上增加仅含多尺度 Gabor 滤波的纹理分支 (texture branch);
 - (5) Baseline+T (Gabor+LBP): 在纹理分支中融合 Gabor 滤波与 LBP 特征;
 - (6) SSR-MobileNetV2-T (Ours): 本文完整模型, 集成双分支结构 (SS 模块、CA 模块及完整的纹理分支 T).
- 表 2 对比了各实验配置下的参数量、准确率和

F1-score, 实验结果如下。

从表 2 可以看出, 逐步添加各模块后, 模型性能持续提升。SS 模块引入后准确率提升约 2.2%, 证明多尺度特征提取对捕获土壤宏观结构信息的有效性。进一步加入 CA 后再提升约 1.7%, *F1-score* 同步提高, 表明注意力机制能有效聚焦关键特征通道, 抑制背景干扰。单独的纹理分支 (T) 对性能提升贡献显著, 其中纹理分支 (Gabor) 带来约 3.4% 的提升, Gabor+LBP 再提升约 0.6%, 验证了二者在描述微观纹理上的互补性。

表 2 消融实验结果对比

实验配置	参数量 (M)	准确率 (%)	<i>F1-score</i> (%)
Baseline	3.4	86.0	85.7
Baseline+SS	3.7	88.2	87.9
Baseline+SS+CA	3.8	89.9	89.5
Baseline+T (Gabor)	4.1	89.4	89.0
Baseline+T (Gabor+LBP)	4.3	91.0	90.7
SSR-MobileNetV2-T (Ours)	4.8	98.1	97.9

本文的完整模型整合了所有模块, 取得最佳性能 (准确率为 98.1%, *F1-score* 为 97.9%), 且参数量仅小幅增加, 保持了模型的轻量化特性。消融实验充分证明各模块设计的必要性与有效性。

3.2 参数敏感性分析

接着, 对纹理提取模块中的关键参数进行敏感性分析, 以验证所选配置的合理性。在 Gabor 滤波器尺度分析中, 测试了多种滤波器尺寸组合 (如[3,5]、[3,5,7]和[5,7,9]) 对模型性能的影响。结果表明, 组合[3,5,7]在特征表达能力与计算效率之间取得最佳平衡: 其中 3×3 小尺度滤波器能够有效捕捉粉土和黏土等细粒土壤的微观纹理特征, 而 5×5 和 7×7 中尺度滤波器适用于提取砂和砾石等粗粒土壤的宏观结构。相比之下, 更大尺寸组合 (如[5,7,9]) 虽然对砾石的识别略有提升, 但细粒土壤的局部纹理信息损失更多, 分类准确率降低, 并增加了不必要的计算量。

在 LBP 参数分析中, 主要评估了邻域点数 (P) 和采样半径 (R) 的不同取值对分类性能的影响。实验结果显示, P=8、R=1 的配置表现最佳, 能够较好地表征土壤图像的局部纹理结构并保持较强的抗噪能力; 而较大的邻域和半径 (如 P=16、R=2) 虽然理论上可以提供更多纹理信息, 但更容易受到成像噪声和光照变化的影响, 导致粉土和黏土等相似类别的性能下降。因此, 本研究所选参数配置合理。

上述敏感性分析结果不仅验证了本文所选参数的合理性, 也为后续相关研究中纹理特征的提取与优化

提供了实验依据。

3.3 对比实验结果

为评估不同图像识别方法在边坡土壤图像分类任务中的性能, 本文系统对比了传统方法: 基于手工特征 (HOG、LBP) 的 SVM; 经典深度学习模型: VGG16、ResNet50; 轻量化模型: 标准 MobileNetV2、EfficientNet-B0、ShuffleNetV2 以及本文提出的 SSR-MobileNetV2-T 模型。对比内容包括模型大小、准确率、*F1-score*、参数量, 对比结果见表 3。

表 3 对比实验结果

方法	模型大小		准确率 (%)	<i>F1-score</i> (%)
	(MB)	(M)		
SVM (HOG+LBP)	≈0.5	—	84.6	83.9
VGG16	≈528	138.4	90.2	89.1
ResNet50	≈98	25.6	91.2	91.7
MobileNetV2	≈14	3.4	93.2	92.8
EfficientNet-B0	≈21	5.3	94.6	94.3
ShuffleNetV2 1.0x	≈9	2.3	94.3	94.0
SSR-MobileNetV2-T (Ours)	18.5	4.8	98.1	97.9

从表 3 可知, 本文提出的 SSR-MobileNetV2-T 模型在准确率和 *F1-score* 上均优于所有对比模型。传统 SVM 方法性能最低, 凸显了手工特征在复杂土壤纹理表征上的局限性。虽然 VGG16 和 ResNet50 性能尚可, 但其庞大的参数量 (远超其他模型) 使其难以部署在移动设备上。在轻量化模型中, 标准 MobileNetV2 的性能证实了其作为强大基线的有效性, 但仍不及本文模型。EfficientNet-B0 和 ShuffleNetV2 作为新兴的高效架构, 性能优于 MobileNetV2, 但与本文模型仍有明显差距 (准确率低 3.5% 以上)。这充分证明本文引入的多尺度纹理融合与注意力机制在土壤图像识别任务中的独特优势, 在保持极轻量级的同时, 实现了最佳的识别精度。

3.4 SSR-MobileNetV2-T 模型实验结果分析

SSR-MobileNetV2-T 模型在 100 轮训练过程中, 验证集准确率逐步上升, 测试损失逐步下降。通过日志文件记录的测试损失和准确率可以分析模型的训练效果。各类型土壤的识别准确率见表 4。

从表 4 可以看出, SSR-MobileNetV2-T 模型在各个类别上都拥有着较高的识别精度, 各个类别上的精确率和召回率均较为平衡, 且均在 96% 以上, 平均准确率、召回率和 *F1-score* 都超过 96%, 其中砾石 (G)、有机土 (O) 和砂 (S) 类别的识别准确率可达约 98% 以上, 各个评价指标都最高。这也说明经过多模块的优化, 尤其是在纹理增强与注意力机制引入后, 模型表现

出显著的性能提升。

预测结果可视化示例如图 14 所示, (a)–(f) 分别对应边坡 1、边坡 2、边坡 3 及边坡 4 在强光、普通光、不同角度条件下的采集图像。所有结果均显示 SSR-MobileNetV2-T 能够准确识别各图像的真实土壤类型, 增强了方法的实验说服力。

表 4 各类型土壤识别结果 (%)

类别	准确率	精确率	召回率	F1-score
砾石 (G)	98.6	98.4	98.6	98.5
砂 (S)	98.8	98.6	98.8	98.7
粉土 (M)	96.5	96.7	96.5	96.6
黏土 (C)	96.2	96.5	96.2	96.3
有机土 (O)	98.2	98.0	98.2	98.1



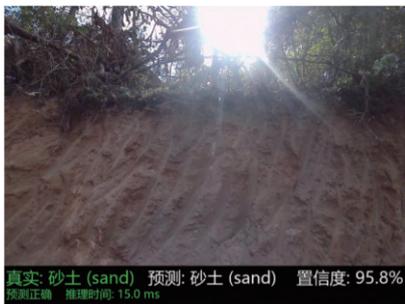
(a) 边坡1



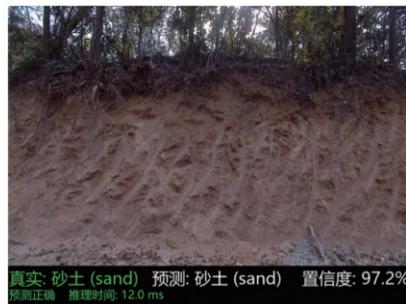
(b) 边坡2



(c) 边坡3



(d) 边坡4 (强光, 角度1)



(e) 边坡4 (普通光, 角度1)



(f) 边坡4 (普通光, 角度2)

图 14 预测土壤类型可视化

SSR-MobileNetV2-T 模型的混淆矩阵如图 15 所示。可以看出: SSR-MobileNetV2-T 模型对砾石、砂、粉土、黏土和有机土这 5 类土壤的识别准确率均超过 95%。其中, 颗粒特征明显的砾石和砂识别效果最佳 (分别为 98.6% 和 98.8%); 纹理相似的粉土与黏土互相误分类比例较高 (分别为 2.22% 和 2.55%), 但仍保持 96% 左右的高精度; 有机土识别误分类很少, 对整体精度影响不大。总体而言, SSR-MobileNetV2-T 模型平均准确率高达 98.1%, 明显优于 MobileNetV2 与 SVM 模型。此外, 通过针对性地扩充易混类别的数据集或优化 Gabor 滤波参数, 有望进一步提升模型的分类效果。

训练过程中的损失值、准确率随训练轮次的关系, 如图 16–图 17 所示。

由图 16 可知, 训练损失曲线随训练轮次增加呈现由高到低持续下降趋势, 并在后期接近于 0, 在训练开始的前 10–15 个训练轮次, 损失值从较高水平快速下降, 反映出模型在初步学习土壤纹理和特征时, 能迅速抓住主要判别信息。当训练 40 轮之后, 准确率达到 90%, 说明识别精度较高; 随着训练轮次增加, 损失曲线的下降速度放缓并趋于平稳, 说明模型对主要特征已充分学习, 仅通过小步长微调来降低损失。后期的波动幅度较小, 表示训练过程稳定, 没有出现显著的过拟合或梯度爆炸等问题。这一现象意味着在训练集上模型几乎可以完美区分各类别。若验证集或测试集上也能保持高准确率, 则说明模型具有良好的拟合能力和一定的泛化性能。

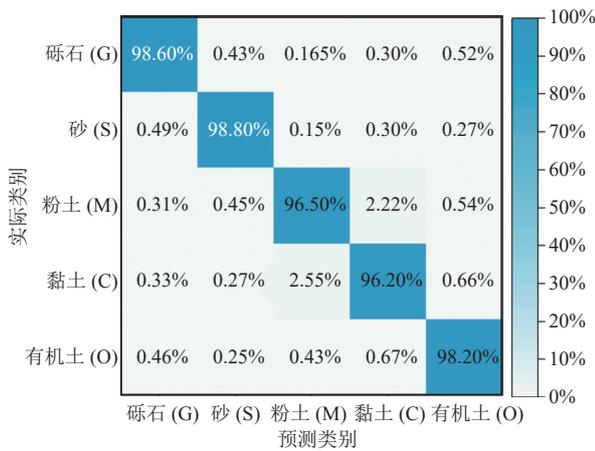


图 15 SSR-MobileNetV2-T 模型混淆矩阵

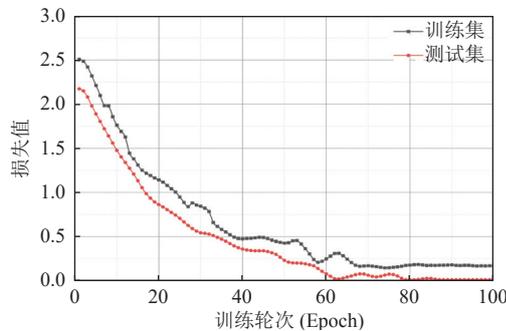


图 16 损失值变化

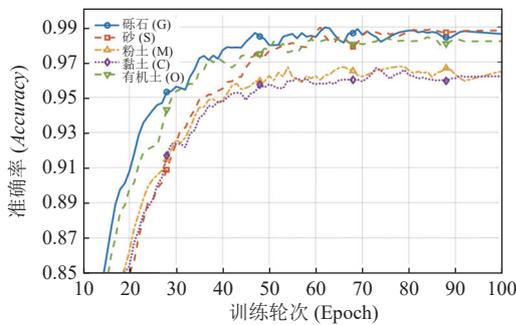


图 17 识别准确率

图 17 中各土壤类型的准确率随训练轮次整体呈现稳定上升趋势,但表现出明显的类别差异.砾石和砂类型的准确率上升最快,在早期训练阶段便已接近收敛,后期曲线波动较小,表明模型对这两类典型纹理特征的土壤具有良好的学习和判别能力.相比之下,粉土和黏土的准确率提升速度相对较慢,且中后期曲线波动较大,反映出模型在细粒、纹理相近土壤上的特征提取和区分仍存在一定难度.有机土的准确率提升过程平稳,表明其特征易于被模型捕捉.整体来看,模型能够在大多数土壤类型上实现准确率的持续提升和有

效收敛,显示出良好的训练效果和较强的泛化能力.

图 15-图 17 共同展示了 SSR-MobileNetV2-T 模型通过专门的纹理特征提取模块,不仅实现了移动端土壤图像识别的轻量化和高精度,还在复杂的边坡环境中展现出对不同土壤类别细微纹理的优越判别能力.训练过程稳定、准确率高(>96%),且在大部分土壤类别上取得极低的错分率,能够为边坡稳定性评估中的土壤识别提供高效而可靠的解决方案.

4 结论与展望

本文针对移动端土壤图像识别任务中的模型复杂度高、纹理特征提取不足等关键问题,提出了一种改进的 SSR-MobileNetV2-T 模型,该模型在保持轻量化设计的同时,显著提升对土壤微观纹理的区分能力,结论如下.

(1) 改进的 SSR-MobileNetV2-T 模型在边坡土壤 5 分类任务中取得 98.1% 的平均识别准确率和 97.9% 的 *F1-score*,显著优于传统 SVM 模型、经典 CNN 模型 (VGG16、ResNet50) 及多种主流轻量化模型 (MobileNetV2、EfficientNet-B0、ShuffleNetV2). 模型对不同类型的土壤,尤其是纹理相似的粉土和黏土,均表现出稳定且高精度的识别能力,训练过程收敛平稳,泛化性能良好.

(2) 消融实验证实,空间多尺度模块、通道注意力机制及融合 Gabor 与 LBP 的纹理分支,均为模型性能提升做出独立且重要的贡献,它们的有效集成是模型成功的关键.

(3) 模型在保持高精度的同时,参数量仅为 4.8M,模型文件大小 18.5 MB,易于部署在移动设备上,满足输变电工程现场对实时性、便携性的要求.

综上所述,本文提出的 SSR-MobileNetV2-T 模型在边坡土壤类型识别任务中实现了轻量化与高精度的兼顾,为输变电工程等场景下的移动端智能识别提供了一种高效、可靠的解决方案,具有重要的工程应用价值.然而,需指出的是,尽管模型在大规模数据库上表现出较强的鲁棒性,但在真实边坡环境中仍可能面临若干挑战.例如,植被、石块及施工设备的遮挡会导致土壤纹理特征被部分掩盖,相机俯仰角度与拍摄距离的变化会带来明显的尺度差异,而土壤湿度条件的动态变化亦可能影响纹理可辨性.这些因素均可能降低模型在现场复杂环境下的可靠性.此外,目前数据库

构建过程中仍依赖人工预处理, 存在一定的人为偏差. 针对上述问题, 未来研究可从两个方向展开: 一是引入语义分割与目标检测模块, 实现对土壤区域的自动化提取, 降低背景干扰; 二是探索端到端联合优化的网络架构, 减少人工预处理环节, 从而进一步提升模型在复杂边坡环境中的适应性与实用性.

参考文献

- 1 刘明, 郭金根, 朱文卫, 等. 输电线路杆塔边坡稳定性分析. 安全与环境学报, 2025, 25(3): 968–977.
- 2 陈树平, 李成, 王彦海, 等. 考虑 SSI 的滑坡区输电塔线体系安全性分析. 安全与环境工程, 2024, 31(5): 135–145.
- 3 王静怡, 吴霜, 翟晓萌, 等. 输电线路工程不同类型塔基边坡径流产沙特征. 水土保持研究, 2024, 31(6): 29–36.
- 4 徐国正, 胡继波, 郑宏利, 等. 渗流作用下非饱和非均质二维边坡稳定性分析. 建筑结构, 2022, 52(S2): 2624–2630.
- 5 赵鹏, 张辉, 禹聪, 等. 水位变动和杆塔荷载对水电站源端输电线路区域边坡稳定性的影响. 水利水电技术(中英文), 2024, 55(S1): 410–417.
- 6 Bian H, Sun Z, Bian J, *et al.* Assessment of soil classification based on cone penetration test data for Kaifeng area using optimized support vector machine. Scientific Reports, 2025, 15: 439. [doi: 10.1038/s41598-024-84632-5]
- 7 Zhu FB, Zhu CD, Lu WH, *et al.* Soil classification mapping using a combination of semi-supervised classification and stacking learning (SSC-SL). Remote Sensing, 2024, 16(2): 405. [doi: 10.3390/rs16020405]
- 8 Wu XY, Wu KN, Hao SH, *et al.* Machine learning ensemble technique for exploring soil type evolution. Scientific Reports, 2025, 15: 24332. [doi: 10.1038/s41598-025-10608-8]
- 9 Aydın Y, Işıkdag Ü, Bekdaş G, *et al.* Use of machine learning techniques in soil classification. Sustainability, 2023, 15(3): 2374. [doi: 10.3390/su15032374]
- 10 Howard A, Sandler M, Chu G, *et al.* Searching for MobileNetV3. Proceedings of the 2019 IEEE/CVF International Conference on Computer Vision (ICCV). Seoul: IEEE, 2019. 1314–1324.
- 11 Tan MX, Le QV. EfficientNet: Rethinking model scaling for convolutional neural networks. Proceedings of the 36th International Conference on Machine Learning. Long Beach: PMLR, 2019. 6105–6114.
- 12 Ma NN, Zhang XY, Zheng HT, *et al.* ShuffleNet V2: Practical guidelines for efficient CNN architecture design. Proceedings of the 15th European Conference on Computer Vision. Munich: Springer, 2018. 122–138.
- 13 Inazumi S, Intui S, Jotiskansa A, *et al.* Artificial intelligence system for supporting soil classification. Results in Engineering, 2020, 8: 100188. [doi: 10.1016/j.rineng.2020.100188]
- 14 Banoth RK, Murthy BVR. Soil image classification using transfer learning approach: MobileNetV2 with CNN. SN Computer Science, 2024, 5(1): 199. [doi: 10.1007/s42979-023-02500-x]
- 15 龙怀玉, 卢昌艾, 冀宏杰, 等. 《第三次全国土壤普查暂行土壤分类系统》土类检索系统构建. 中国农业科学, 2024, 57(21): 4264–4275.
- 16 袁大刚. 第三次全国土壤普查土壤分类系统修订建议. 土壤, 2025, 57(1): 231–237.
- 17 Shi GS, Sun WY, Shangguan W, *et al.* A China dataset of soil properties for land surface modelling (version 2, CSDLv2). Earth System Science Data, 2025, 17(2): 517–543. [doi: 10.5194/essd-17-517-2025]
- 18 Gyasi EK, Purushotham S. Soil-MobiNet: A convolutional neural network model base soil classification to determine soil morphology and its geospatial location. Sensors, 2023, 23(15): 6709. [doi: 10.3390/s23156709]
- 19 Raihan A, Fayaz SM, Ahmed J, *et al.* Soil moisture dataset for image based soil classification. Mendeley Data, V2, 2025. [\(https://data.mendeley.com/datasets/skcc44yvvg/2\)](https://data.mendeley.com/datasets/skcc44yvvg/2). (2025-08-27)[2025-10-14].
- 20 Srivastava P, Shukla A, Bansal A. A comprehensive review on soil classification using deep learning and computer vision techniques. Multimedia Tools and Applications, 2021, 80(10): 14887–14914. [doi: 10.1007/s11042-021-10544-5]
- 21 曾绍华, 廖凌羽, 王帅, 等. 基于土壤分类系统的残差图卷积土种识别研究. 西南农业学报, 2025, 38(09): 2008–2020 [doi: 10.16213/j.cnki.scjas.2025.9.020]
- 22 Moreira G, Magalhães SA, Pinho T, *et al.* Benchmark of deep learning and a proposed HSV colour space models for the detection and classification of greenhouse tomato. Agronomy, 2022, 12(2): 356. [doi: 10.3390/agronomy12020356]
- 23 田一禾, 焦心, 孙强强, 等. 中国旱地系统地表植被-土壤状态演化路径识别与过程分析. 测绘通报, 2024(12): 149–154.
- 24 刘博文, 徐卫平, 徐钦, 等. 基于改进 YOLOX 的猕猴桃分类识别与空间定位. 国外电子测量技术, 2024, 43(4): 133–142.
- 25 Hu J, Shen L, Sun G. Squeeze-and-excitation networks. Proceedings of the 2018 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). 2018. 7132–7141. [doi: 10.1109/CVPR.2018.00745]
- 26 傅志翔, 张元勋, 王历辉, 等. 基于纹理特征的糖网临床前期眼底自发荧光图像识别. 计算机系统应用, 2019, 28(1): 251–255. [doi: 10.15888/j.cnki.csa.006727]

(校对责编: 李慧鑫)