

基于 Gabor 特征提取和 MobileNetV2 在云南天牛识别中的应用

徐全元^{1,2}, 明念坤³, 邓维杰¹, 鲁莹^{1,2*}

1. 西南林业大学大数据与智能工程学院, 云南 昆明 650224
2. 云南省高校生物多样性大数据挖掘与应用重点实验室, 云南 昆明 650224
3. 中国石油大学(北京)人工智能学院, 北京 102249

摘要: 天牛是对林木健康构成重大威胁的害虫,其分类和识别对于生态学、农业和环境保护至关重要。天牛分类方法中,通常采用传统的形态学分类法,但存在效率较低等问题。本文以云南常见的10种天牛为研究对象,采集天牛标本和自然背景图片作为数据集,通过2D Gabor滤波器对天牛图像进行特征提取,引入轻量化的迁移学习模型 MobileNetV2 进行分类。实验对比了局部二值模式(LBP)、灰度共生矩阵(GLCM)、尺度不变特征变换(SIFT)提取特征方法与支持向量机(SVM)、随机森林(RF)分类器,以及VGG16、ResNet101、InceptionV3和MobileNetV2模型的组合性能。结果表明,LBP_RF和GLCM_RF的准确率分别为61.93%和67.93%;原始数据集(SWFU LHB 10)在VGG16、ResNet101、InceptionV3和MobileNetV2上的准确率分别为70.90%、41.53%、76.10%和83.07%;SIFT特征提取后模型性能普遍下降;而在Gabor特征提取的基础上,MobileNetV2模型识别准确率提升至98.94%,F1-score达98.80%,因此,采用2D Gabor滤波器结合MobileNetV2模型进行天牛分类的方法,在特征提取和模型训练方面均显著优于其他方法,为天牛识别提供了有效的解决方案,对天牛的综合防治具有重要意义,也可为相关行业领域提供参考。

关键词: 天牛识别; 2D Gabor; 特征提取; MobileNetV2; 深度学习

中图法分类号: TP391

文献标识码: A

文章编号: 1000-2324(2026)02-0321-11

Application of Gabor Feature Extraction and MobileNetV2 in Yunnan Longicorn Beetle Identification

XU Quan-yuan^{1,2}, MING Nian-kun³, DENG Wei-jie¹, LU Ying^{1,2*}

1. College of Big Data and Intelligent Engineering/Southwest Forestry University, Kunming 650224, China
2. Yunnan Provincial Key Laboratory of Biodiversity Big Data Mining and Application in Colleges and Universities, Kunming 650224, China
3. College of Artificial Intelligence/China University of Petroleum, Beijing 102249, China

Abstract: Longicorn beetles pose a significant threat to forest health, making their classification and identification crucial for ecology, agriculture, and environmental protection. Typically, existing classification methods rely on traditional morphological taxonomy, which suffers from low efficiency and limited accuracy. This paper focuses on 10 common species of longhorn beetles in Yunnan Province, utilizing a dataset comprising collected specimens and images with natural backgrounds. It applies a 2D Gabor filter to extract image texture features, and introduces the lightweight transfer learning model MobileNetV2 for classification. The study compares the performance of feature extraction methods, including Local Binary Pattern (LBP), Gray Level Co-occurrence Matrix (GLCM), and Scale Invariant Feature Transform (SIFT), combined with classifiers such as Support Vector Machine (SVM), Random Forest (RF), as well as models like VGG16, ResNet101, InceptionV3, and MobileNetV2. The Results indicate that the classification accuracies of LBP_RF and GLCM_RF are 61.93% and 67.93%, respectively. The accuracy of the original dataset (SWFU LHB 10) on VGG16, ResNet101, InceptionV3, and MobileNetV2 reaches 70.90%, 41.53%, 76.10%, and 83.07%, respectively. However, performance declines after applying SIFT features. In contrast, combining Gabor features with MobileNetV2 significantly improves the classification accuracy to 98.94%, with an F1-score of 98.80%. Therefore, the proposed method based on 2D Gabor filtering and MobileNetV2 significantly outperforms other approaches in both feature extraction and model training. It provides an effective solution for longhorn beetle identification.

Keywords: Beetle classification; 2D Gabor; feature extraction; MobileNetV2; deep learning

收稿日期: 2025-04-02

修回日期: 2026-03-08

基金项目: 云南省教育厅科学研究基金项目(2022J0493)

第1作者简介: 徐全元(1979-),男,博士,副教授,研究方向:森林保护学。E-mail: xuqy@swfu.edu.cn

*通讯作者: Author for correspondence. E-mail: 80439808@qq.com

天牛是鞘翅目 Coleoptera 叶甲总科 Chrysomeloidea 天牛科 Cerambycidae 昆虫的总称,触角常超过身体,成虫大小、形状因种类而异,小的不足 1 cm,大的超过 8 cm^[1,2]。李丽莎等编著的《云南天牛》中记录了云南天牛昆虫 512 种,占云南已鉴定天牛总数的 49.41%^[3]。云南省是我国的林业大省,截至 2021 年底,云南林地面积 0.25×10^8 hm²,森林面积 0.21×10^8 hm²,均居全国第二位^[4]。近年来,随着人工纯林面积持续扩大,单一树种造林模式导致森林生态系统结构简化、稳定性降低,抗病虫害能力减弱,极易诱发天牛等植食性昆虫的高密度暴发,对森林健康构成严重威胁^[5]。天牛种类繁多且成虫形态特征相似性高,加之种间差异细微,给准确鉴定带来较大困难。因此,云南天牛的快速准确识别不仅为物种多样性的编目与保护策略的制定提供了科学依据,也为农林害虫的监测预警与精准防控措施的制定提供了技术支撑^[6]。

近年来,针对天牛的识别研究也逐渐增加,谭亮魁^[7]等通过使用分子标记(RAPD/RFLP/AFLP)和核酸序列分析(线粒体及核基因)的方法对天牛进行分类识别研究;付甫永^[8]等通过传统形态学方法,对危害贵州省核桃的蛀干害虫进行系统分类,成功鉴定出白条云斑天牛,为当地核桃树病虫害防治提供了重要参考;满庆丽^[9]融合 SIFT 与颜色特征并结合 SVM 分类器,实现了 86.5% 的识别精度,验证了多特征融合的有效性;夏令^[10]采用 VMD 降噪和子带阈值法处理天牛幼虫蛀木振动信号,为天牛种类识别开辟了新的技术路径。综合来看,针对天牛的研究主要停留在传统技术层面,缺乏与现代深度学习、机器学习技术的结合。然而,随着计算机视觉和深度学习技术的迅猛发展,相关领域已展现出巨大潜力。慕君林等^[11]研究表明,深度学习方法能显著提升病虫害检测精度;彭鑫^[12]提出的 GCHCNet 深度学习模型,通过集成 GhostNet、胶囊网络和 CBAM 注意力机制,在 14 类农业害虫识别中达到了 97.6% 的识别准确率;孙丰刚等^[13]将 YOLOv5s 与边缘计算技术相结合,开发出准确率达 94.4% 的天牛智能监测系统。基于以上研究进展,结合 Gabor 特征提取和深度学习方法,以期为解决当前天牛识别方法存在的问题提供新的思路和解决方案。

Marcelja^[14]和 Daugman^[15]率先提出了视觉皮层中的简单细胞可用 Gabor 函数建模,Daugma 进

一步指出 2D Gabor 函数是一种局部空间带通滤波器,能够在二维空间域和傅里叶域中实现信息的最优联合分辨,从而推动了 Gabor 特征在图像处理领域的广泛应用。杨旺功^[16]等将 Gabor 小波特征提取与深度神经网络相结合,开发出高效的葡萄种子图像分类识别算法。Hu 等^[17]基于 Gabor 的良好特性结合 CNN 方法构建了 Gabor-CNN 模型,该模型能够有效进行基于少量样本的目标检测。魏祥坡等^[18]使用 CNN 技术结合 Gabor 滤波器对高光谱图像进行分类实现了较好的分类精度。大量的研究证明了 Gabor 在特征提取方面的良好特性^[19,20],为将其运用到天牛图像分类提供了理论和实践基础。随着深度学习技术的发展,越来越多的研究者将其应用到昆虫研究中。蒋心璐等^[21]介绍了针对农业害虫检测的深度学习算法研究现状,总结了改进策略和技术细节并展望了未来研究趋势。周爱明等^[22]开展了深度学习模型在蝴蝶科级标本图像自动识别中的可行性和泛化能力研究,研究证明了基于深度学习的蝴蝶识别模型具有较好的泛化能力。张洁^[23]在去除图像背景的前提下,以 680 个样本作为训练集,170 个样本作为测试集,对 34 种农作物害虫的识别准确率为 86.7%。研究表明,深度学习已经能够较好的应用于昆虫研究领域,但仍存在识别效率较低、资源耗费较大,准确率和模型泛化性不足等情况。为了解决当前问题,SANDLER^[24]提出了 MobileNetV2 网络结构,实验证明该网络结构能够显著减少所需的操作数量和内存,同时保持相同的准确性,推动了移动定制计算机视觉模型的发展。李国进等^[25]采用 MobileNetV2 网络实现了酿酒葡萄轻量级检测模型,并取得了较好结果。刘张等^[26]使用 MobileNetV2 提取特征,经通道注意力模块融合多尺度特征并输出分类,提高了小肠溃疡性病灶的识别准确度和效率。杨国亮等^[27]对 MobileNetV2 网络进行了改进,在保持分类准确率的同时缩减了网络规模,提高了计算速度,证明了 MobileNetV2 网络在遥感应用领域的实用性。

综上所述,Gabor 滤波器和 MobileNetV2 网络均在各研究领域有广泛应用,为研究提供了良好的支撑。本文旨在通过 Gabor 特征提取结合 MobileNetV2 网络模型,构建一种轻量级的天牛识别模型,以支持天牛的有效识别和综合防治。针对

云南地区常见的10种天牛进行研究,所构建的模型在保持较高准确性的同时,显著减少了操作数量和内存需求,可有效地对天牛进行分类和识别。

1 材料与方法

1.1 数据采集与预处理

本文通过西南林业大学标本馆、Kaggle 平台、昆明动物博物馆、实地拍摄等多种方式采集数据。通过整理分析,最终选取了10种不同属、样本数量相对较多且对农、林业有一定危害性的

天牛作为研究对象。在进一步开展研究工作之前,首先需要对采集到的图像数据进行人工标注、确认。其次由于通过多种方式采集的图像大小难以统一,部分类别样本数据较少。为提升特征提取的数据性能和分类模型的可靠性,增强目标物体的识别能力,并避免网络过拟合,本文收集了10类天牛图像,共计5 656幅,图像格式多样。为确保数据一致性,将所有图像分辨率统一调整至256×256像素,并转换为jpg格式。同时,进行了人工标注和确认,最终构建了名为SWFU LHB 10的数据集(表1)。

表1 数据集信息
Table 1 Dataset information

序号 Number	属 Genus	中文名称 Chinese name	拉丁名 Scientific name	SWFU LHB 10
1	颈天牛属	桃颈天牛	<i>Aromia bungii</i>	577
2	星天牛属	星天牛	<i>Anoplophora chinensis</i>	857
3	粒肩天牛属	桑天牛	<i>Apriona germari</i>	439
4	绿虎天牛属	竹绿虎天牛	<i>Chlorophorus annularis</i>	615
5	红天牛属	红天牛	<i>Eurythrus championi white</i>	230
6	墨天牛属	松墨天牛	<i>Monochamus alternatus</i>	507
7	鹿天牛属	长颈鹿天牛	<i>Macrochenus guerinii</i>	505
8	紫天牛属	竹紫天牛	<i>Purpuricenus temminckii</i>	376
9	丽天牛属	丽天牛	<i>Rosalia serville</i>	450
10	脊虎天牛属	脊虎天牛	<i>Xylotrechus chevrolat</i>	1 100

1.2 特征提取方法

2.1.1 LBP、GLCM 和 SIFT 特征提取 本文采用局部二值模式(Local Binary Pattern, LBP)^[28]、灰度共生矩阵(Gray Level Co-Occurrence Matrix, GLCM)^[29]和尺度不变特征变换(Scale Invariant Feature Transform, SIFT)^[30]特征提取方法提取天牛图像的纹理特征信息。LBP是一种用来描述图像局部纹理特征的算子,具有旋转不变性和灰度不变性等显著的优点,常被用于图像纹理特征的提取。GLCM定义为像素对的联合分布概率,是一个对称矩阵,它不仅反映图像灰度在相邻的方向、相邻间隔、变化幅度的综合信息,也反映了相同的灰度级像素之间的位置分布特征,是计算纹理特征的基础。SIFT则可在不同尺度下提取关键点,具有良好的尺度和旋转不变性。

2.1.2 Gabor 特征提取 2D Gabor 卷积核与哺乳动物视觉皮层中简单细胞的2D感受野轮廓非常

相似^[31],具有良好的空间局部性和方向选择性,能够捕捉图像局部区域多个方向的空间频率和局部结构特征,且 Gabor 小波变换对光照和物体姿态的变化具有很强的鲁棒性,因此在图像处理、机器学习等领域有着广泛的应用^[32]。Gabor 函数有实部和虚部,实部滤波后图像会变平滑,虚部滤波后可检测边缘。得益于2D-Gabor 滤波器在空间域和频率域能同时取得最优局部化信息,能描述对应空间频率、位置及方向选择性的局部结构信息,以及主要关注纹理特性等优势。因此本文选用2D-Gabor 滤波器提取天牛图像的纹理特征。二维 Gabor 的表达式如式(1)~(3)所示。

$$G(x, y, \lambda_1, \theta_1, \psi_1, \sigma_2, \gamma_1) = \exp \left[- \frac{x^2 + \gamma_1^2 y^2}{2\sigma_2^2} \right] \exp \left[i \left(2\pi \frac{x'}{\lambda_1} + \psi_1 \right) \right] \quad (1)$$

$$G_{real}(x,y,\lambda_1,\theta_1,\psi_1,\sigma_2,\gamma_1) = \exp \left[- \left(\frac{x^2 + \gamma_1^2 y^2}{2\sigma_2^2} \right) \right] \cos \left(2\pi \frac{x'}{\lambda_1} + \psi_1 \right) \quad (2)$$

$$G_{imaginary}(x,y,\lambda_1,\theta_1,\psi_1,\sigma_2,\gamma_1) = \exp \left[- \left(\frac{x^2 + \gamma_1^2 y^2}{2\sigma_2^2} \right) \right] \sin \left(2\pi \frac{x'}{\lambda_1} + \psi_1 \right) \quad (3)$$

其中 x 和 y 表示像素在空间域中的位置坐标, $x' = x\cos\theta + y\sin\theta, y' = -\sin\theta + y\cos\theta, \lambda_1$ 是正弦函数的波长, θ_1 为 Gabor 核函数的方向, 取值范围为 $0 \sim 360^\circ$; ψ_1 表示相移; σ_2 是高斯函数的标准偏差; γ_1 表示空间的纵横比。在此基础上, 本文构建 Gabor 滤波器对天牛图像进行特征提取, 如图 1 所示, 特征提取流程首先输入天牛图像, 通过 Gabor 特征提取得到最终提取后的 Gabor 特征图像。




图 1 Gabor 特征提取流程
Fig. 1 Gabor feature extraction process

Gabor 滤波器构建自定义参数波长 λ 为 $\pi/2$, 空间的纵横比 γ 为 0.5, 相位偏移 ψ 为 1.0, 滤波方向 θ 设置为 90° , 设置 3 个尺度 $Ksize=[3, 5, 7]$, 构建 Gabor 滤波器。滤波器构建后与输入图像进行卷积运算, 得到最终的 Gabor 特征图像。

1.3 分类模型构建

MobileNetV2 网络架构是基于倒置残差结构 (Inverted Residual Structure) 的一种新的神经网络结构^[24], 该结构专门针对移动和资源受限的环境。该网络在保持相同的准确性的同时, 能显著减少所需的操作数量和内存, 因此推动了移动定制计算机视觉模型的发展。

MobileNetV2 是基于 MobileNetV1^[33] 网络的改进, 主要贡献是 Inverted Residuals block 和 Linear Bottlenecks。与传统残差网络中“降维-卷积-升维”的结构不同, 倒残差结构采用“升维-深度可分离卷积-降维”的顺序, 即首先通过 1×1 卷积进行升维, 然后利用 3×3 深度可分离卷积 (Depthwise Convolution) 提取空间特征, 最后通过 1×1 卷积降维。该结构设计能有效减少高维特征在 ReLU 激活函数中信息丢失的风险。此外, 线性瓶颈结构去除了输出维度较小层后的非线性激活函数, 使用线性激活代替, 从而进一步减缓信息损失。本文在 MobileNetV2 网络结构的基础上, 采用迁移学习方法实现对小样本天牛图像的高效分类。MobileNetV2 原始模型是在

ImageNet 数据集 (包含超过百万张图像) 上训练得到的, 具备丰富的图像识别特征表达能力。而本文所使用的 SWFU LHB 10 数据集中图像数量相对较少, 且图像差异较细微, 因此采用迁移学习策略更为适宜。具体做法是保留 MobileNetV2 所有卷积层权重, 仅替换其最后 3 层, 即去除原有的全局平均池化层、全连接层及 SoftMax 分类器, 并重新构建用于本研究的分类结构。如图 2 所示, 修改后的网络结构依次包括 MobileNetV2 卷积层、全局平均池化层 (Global Average Pooling, GAP)、512 维全连接层及 SoftMax 输出层, 用于实现 10 类天牛的识别。图中 $7 \times 7 \times 1280$ 表示卷积层输出的特征图大小为 7×7 , 通道数为 1280; 1280 表示经过全局平均池化后压缩为一维特征向量; 512 为全连接层的输出维度; 10 则为 SoftMax 分类输出, 对应于数据集中 10 种天牛类别。通过全局平均池化不仅能减少模型参数数量, 还可有效防止过拟合。

1.4 模型评价

为了准确地评估本文构建模型的性能, 本文使用准确率、精确率、召回率和 F1 分数标准指标评估训练模型在识别个体天牛方面的表现。在模型评价指标中, False Negative (FN) 被判定为负样本, 但事实上是正样本。False Positive (FP), 被判定为正样本, 但事实上是负样本。True Negative (TN), 被判定为负样本, 事实上也




图 2 MobileNetV2 迁移学习模型结构图

Fig. 2 MobileNetV2 transfer learning model structure diagram

是负样本。True Positive(TP),被判定为正样本,事实上也是正样本。

准确率(Accuracy):分类模型总体判断的准确率(包括了所有 class 的总体准确率)

$$\text{Accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}} \quad (4)$$

精确率(Precision):表示被分为正例的样本中实际为正例的比例:

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (5)$$

召回率(Recall):召回率是覆盖面的度量,度量有多个正例被分为正例:

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (6)$$

F1 Score:是统计学中用来衡量二分类模型精确度的一种指标。它同时兼顾了分类模型的精确率和召回率。

$$\text{F1(Score)} = \frac{2 \cdot \text{Precision} \cdot \text{Recall}}{\text{Precision} + \text{Recall}} \quad (7)$$

1.5 实验平台

本实验采用的硬件平台为内存 128 G,CPU 为 12 核 24 线程的 Ryzen 9 3900X 其主频 3.40 GHz, GPU 为 3090 24 G, 硬盘为 1 T 的 SSD 固态和 16 T 的机械硬盘的台式计算机。使用 Windows 10 服务器版操作系统,安装软件为 Annaconda3, PyCharm2021, Python3.7, Tensorflow 2.6.0 的深度学习平台。

2 结果与分析

2.1 天牛识别系统

天牛识别系统包含 3 个模块:数据采集和预处理、特征提取、分类模型建立和评价。首先,通过多种数据采集方法采集实验数据,并将采集后的图像进行预处理。其次,针对预处理后数据,

选用特征提取方法提取天牛图像特征。最后,将提取的特征其输入到分类方法中进行训练,构建天牛分类模型,并采用不同指标对模型进行评价(图 3)。

模块 1:数据采集与预处理。此模块主要包含数据集的获取途径和图像的预处理操作,本文通过网络采集、标本馆采集、实地拍摄等 3 种方式获取原始的天牛图像数据。预处理数据包含数据集的人工标注、裁剪等过程,实现对数据集的处理,最终将数据统一处理为同一尺寸大小。

模块 2:特征图像提取。此模块主要针对预处理后的图像采用局部二值模式(LBP)、灰度共生矩阵(GLCM)、尺度不变特征变换(SIFT)和 Gabor 等特征提取方法进行特征提取。

模块 3:模型构建与评价。对提取的 LBP 和 GLCM 特征图像采用随机森林(Random Forest, RF)^[34]和支持向量机(Support Vector Machine, SVM)^[35]分类模型进行分类模型构建,对提取的 SIFT 和 Gabor 特征图像,分别将其输入到 MobileNetV2、VGG16^[36]、InceptionV3^[37]、ResNet101^[38]等卷积神经网络模型进行训练,模型训练后通过 Accuracy、Precision、Recall、F1-score 等模型评价方法对模型进行评估,获得最终的分类结果。

2.2 天牛图像特征提取

特征提取后,天牛物种原始图像数据(SWPU LHB 10)、LBP 特征数据集(LBP-SWPU LHB 10)、GLCM 特征数据集(GLCM-SWPU LHB 10)、SIFT 特征数据集(SIFT-SWPU LHB 10)和 2D-Gabor 特征数据集(Gabor-SWPU LHB 10)的样本数量见表 2。

特征提取后,结合表 3 所示的 10 类天牛图

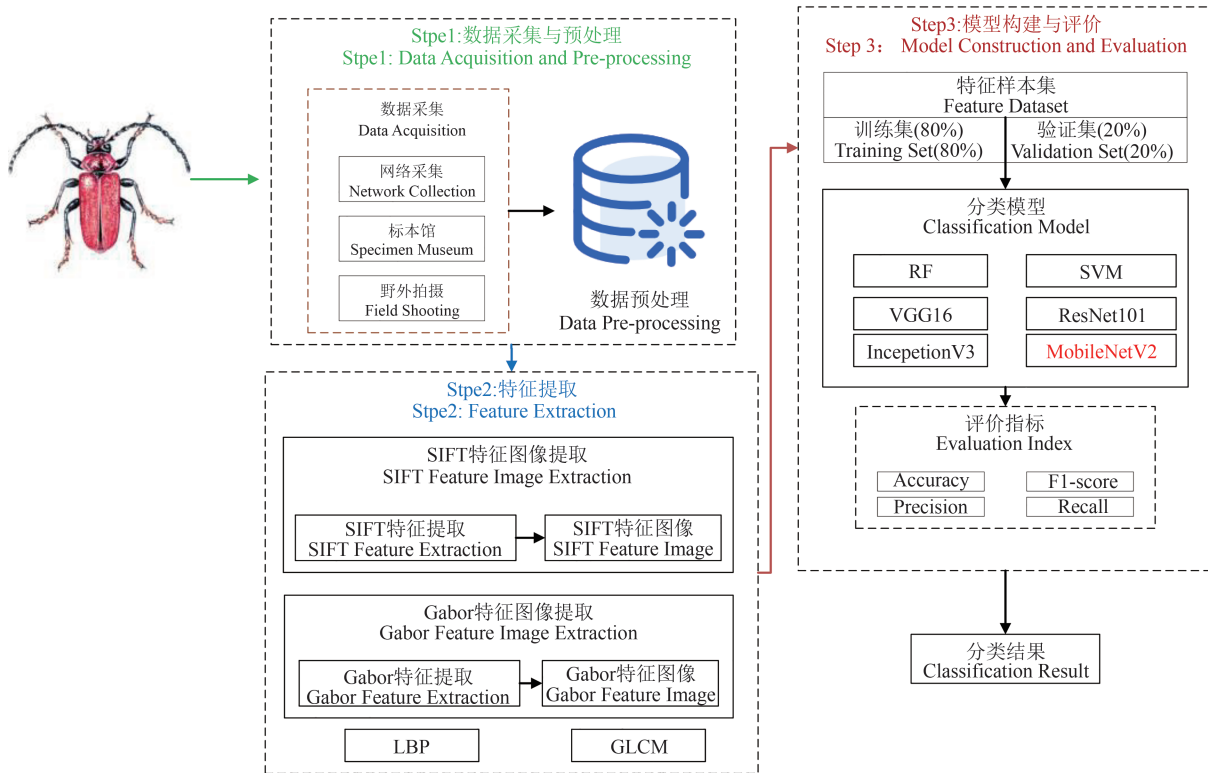


图 3 天牛识别系统

Fig. 3 Longicorn beetle identification system

表 2 图像数据信息

Table 2 Image data information

序号 Number	名称 Longhorn beetle name	SWFU LHB 10	LBP-SWFU LHB 10	GLCM-SWFU LHB 10	SIFT-SWFU LHB 10	Gabor-SWFU LHB 10
1	桃颈天牛	577	577	577	577	1 731
2	星天牛	857	857	857	857	2 571
3	桑天牛	439	439	439	439	1 317
4	竹绿虎天牛	615	615	615	615	1 845
5	红天牛	230	230	230	230	690
6	松墨天牛	507	507	507	507	1 521
7	长颈鹿天牛	505	505	505	505	1 515
8	竹紫天牛	376	376	376	376	1 128
9	丽天牛	450	450	450	450	1 350
10	脊虎天牛	1 100	1 100	1 100	1 100	3 300

像特征信息,分别选取每类一张代表图像进行对比分析,结果如图 4 所示。图中每列对应 1 种天牛,共 10 类样本,每类依次展示原始图像、SIFT 特征图像和 Gabor 特征图像。第 1 行为原始图像,可观察到天牛在体型、体色、斑点和触角等方面存在明显差异,为后续识别提供了直观基础。第 2 行为 SIFT 提取的结构特征图像,关键点主要集中于体节边缘、触角和翅鞘

区域,具备良好的尺度与旋转不变性。部分种类(如 *Purpuricenus temminckii* 和 *Chlorophorus annularis*)的特征点密集,表明其结构细节丰富。第 3 行为尺度为 5 的 Gabor 滤波图像,强化了翅鞘纹理、斑点和肢体轮廓等局部纹理信息,提升了类间区分度。第 3 行为尺度为 5 的 Gabor 滤波图像,增强了翅鞘纹理、斑点和肢体轮廓等局部纹理信息,提高了类间可分性。因

表 3 天牛图像特征信息
Table 3 Image feature information of longicorn beetles

序号 Number	名称 Longhorn beetle name	特征 Characteristic
1	桃红颈天牛	体长 24.0~40.0 mm; 体亮黑色, 胸部棕红色, 有光泽; 触角及足黑蓝紫色, 头黑色, 腹面有许多横皱。
2	星天牛	体长 19.0~39.0 mm, 体宽 6.0~13.5 mm; 体漆黑色, 略带金属光泽, 具白色小星斑; 触角自第 3 节起各节基部淡蓝白色, 体腹面被银灰色和蓝灰色茸毛。
3	桑天牛	雌虫体长 31.0~44.0 mm, 宽 9.0~12.0 mm, 雄虫略小。黑褐色, 体密被铁锈色绒毛。头、胸及鞘翅基部颜色较深。触角 10 节, 1~4 节下方具毛, 第 4 节中部以后各节黑褐色。
4	竹绿虎天牛	体型狭长, 棕色或棕黑色, 头部及背面密被黄色绒毛, 腹面被白绒毛, 足部有时赤褐色; 前胸背板具 4 个长形黑斑, 中央两个至前端合并; 鞘翅基部一卵圆形黑环。
5	红天牛	体长 13.0~21.0 mm; 体宽: 4.0~7.0 mm; 体中等大小, 较粗壮, 红色, 触角、足、中胸腹板、后胸腹板及腹部黑色; 前胸背板中区有 1 对圆形瘤状黑色毛斑。
6	松墨天牛	体长 15.0~28.0 mm; 体橙黄色到赤褐色, 鞘翅上饰有黑色与灰白色斑点; 前胸背板有 2 条相当宽的橙黄色条纹, 与 3 条黑色纵纹相间; 小盾片密被橙黄色绒毛。
7	长颈鹿天牛	体长 13.5~30.0 mm。头被灰色或红灰色绒毛, 后头有 4 条平行较宽黑色纵条纹, 额中央有 1 个略呈三角形黑斑纹。前胸背板黑色有 3 条平行的淡黄色或白色绒毛纵条纹。
8	竹紫天牛	体长 11.5~18.0 mm, 宽 4.0~6.5 mm; 头、触角、小盾片、体腹面及足黑色; 前胸背板及鞘翅朱红色, 均密布刻点, 且前者宽约为长的 2 倍。
9	丽天牛	体长: 19.0~33.0 mm; 体宽: 5.5~9.0 mm; 体较大, 被橙黄或桔红色绒毛, 有黑斑纹; 头、触角、小盾片、中胸腹板、后胸腹板、腹部及足黑色; 头顶有时具橙黄色绒毛。
10	脊虎天牛	体长 11.0~15.0 mm; 体黑色, 全身被覆浓密黄色绒毛, 体背面不着生黄色绒毛处, 形成黑色斑纹; 体腹面绒毛淡黄或黄绿色; 触角、足黄褐, 腿节大部分黑褐。

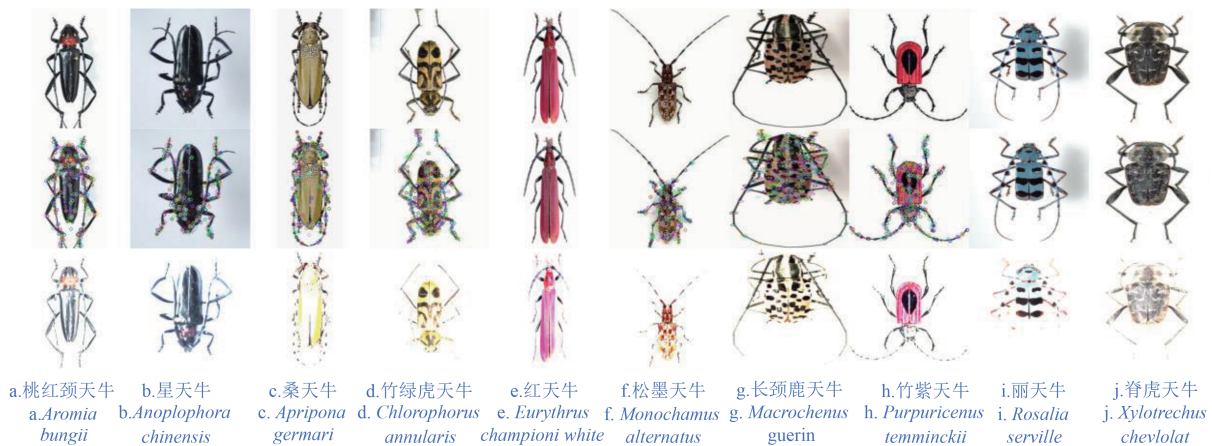


图 4 天牛原始图像与特征提取效果对比图

Fig. 4 Comparison of the original images and feature extraction results of longicorn beetle

此, SIFT 侧重于提取图像中的关键结构信息, 而 Gabor 方法更关注纹理表达, 提取过程中弱化了其他非纹理特征。

2.3 模型识别结果评价

针对 LBP、GLCM 特征数据, 选用传统机器学习方法随机森林(RF)构建分类模型 LBP-RF 和 GLCM-RF。针对 SIFT 和 Gabor 提取特征数据集, 采用 InceptionV3、ResNet101、VGG16 和

MobileNetV2 模型, 设置 Epoch 为 50, 选择 Adam 优化算法设置学习率为 0.000 1 构建分类模型。最后, 通过准确率 (Accuracy)、精确率 (Precision)、F1 分数 (F1-score) 和召回率 (Recall) 等指标对模型性能进行评估, 并在验证集上对各模型的评估结果进行了汇总(表 4)。

通过实验得到 LBP、GLCM 结合随机森林构

表 4 模型识别结果
Table 4 Model recognition results

数据集 Dataset	模型 Model	准确率/% Accuracy	精确率/% Precision	召回率/% Recall	F1 分数/% F1-score	训练时间/s Training time
LBP	Random Forest	61.93	64.40	55.70	56.80	15
GLCM	Random Forest	67.93	70.20	65.70	66.50	10
SWFU LHB 10	VGG16	70.90	74.60	69.80	71.40	215
	ResNet101	41.53	44.60	39.90	40.40	370
	InceptionV3	76.10	76.30	75.70	75.70	353
	MobileNetV2	83.07	84.70	82.40	83.00	196
	VGG16	62.26	65.80	60.20	62.20	226
SIFT-SWFU LHB 10	ResNet101	42.68	46.40	35.10	34.90	379
	InceptionV3	63.23	63.10	61.10	61.60	375
	MobileNetV2	68.96	68.50	68.10	68.20	199
	VGG16	85.78	86.60	85.80	86.00	537
Gabor-SWFU LHB 10	ResNet101	53.75	57.30	49.90	51.50	960
	InceptionV3	98.59	98.70	98.50	98.70	911
	MobileNetV2	98.94	99.00	99.00	98.80	482

建模型, SWFU LHB 10、SIFT-SWFU LHB 10、Gabor-SWFU LHB 10 数据集分别结合 VGG16、ResNet101、MobileNetV2 和 InceptionV3 构建模型的结果。模型按照“数据集_模型”(例:SWFU LHB 10_VGG16 代表 SWFU LHB 10 数据集在 VGG16 模型上训练的天牛分类模型)进行命名, 训练 5 组数据, 共得到 14 个分类模型。结果表明, 传统机器学习方法构建的 LBP_RF 模型和 GLCM_RF 模型建立时间最少, 但是模型准确率较低。在深度学习模型, MobileNetV2 模型在 SWFU LHB 10 数据集获得 83.07% 的准确率, 所用时间为 196 s; 在 SIFT-SWFU LHB 10 数据集获得 68.96% 的准确率, 所用时间为 199 s; 在 Gabor-SWFU LHB 10 数据集获得 98.94% 的准确率, 所用时间为 482 s; 使用 Gabor-SWFU LHB 10 的准确率比 SIFT-SWFU LHB 10 高出 36.68%, 比 SWFU LHB 10 高 15.87%, 比 LBP_RF 高 37.01%, 比 GLCM_RF 高 31.01%。从模型训练时间和准确率比较结果分析可知, MobileNetV2 模型能够在有效保证精度的同时使模型训练时间最少。因此, 选用此方法构建模型能够极大提升模型的性能, 且能够有效保障识别模型的有效性和准确性。

(1) 不同数据集比较 表 4 显示了根据不同数据集在随机森林、VGG16、ResNet101、InceptionV3 和 MobileNetV2 模型上的验证结果。

不同数据集对比结果表明 Gabor 特征图像构建的识别模型各项指标高于 LBP、GLCM、SIFT 特征图像和原始图像数据集构建的识别模型。实验充分说明了基于 Gabor 特征提取方法在天牛识别的有效性。

(2) 不同模型比较 实验使用 LBP、GLCM、SWFU LHB 10、SIFT-SWFU LHB 10 和 Gabor-SWFU LHB 10 数据集分别在模型 RF、VGG16、ResNet101、MobileNetV2 和 InceptionV3 进行训练和验证, 获得表 4 结果。实验结果表明, 在使用不同数据集构建的识别模型中, MobileNetV2 模型各项指标均取得了最好的性能, 证明了 MobileNetV2 方法在天牛识别研究中的有效性。为了更好的对实验结果进行分析, 实验画出各模型在不同验证数据集准确性和损失率随模型训练的变化情况(图 5)。

在图 5a、c、e 中, MobileNetV2 的准确率在训练过程中随着 epoch 的增加而增加, 在训练过程中一直处于最高位置, 并且波动很小, 说明 MobileNetV2 模型在训练过程中较易收敛且准确率较稳定。在图 5b、d、f 中, MobileNetV2 的损失收敛得更快并且变化很小。实验结果表明, MobileNetV2 模型能够取得更好的识别效果, 模型性能更稳定, 有助于实际应用。

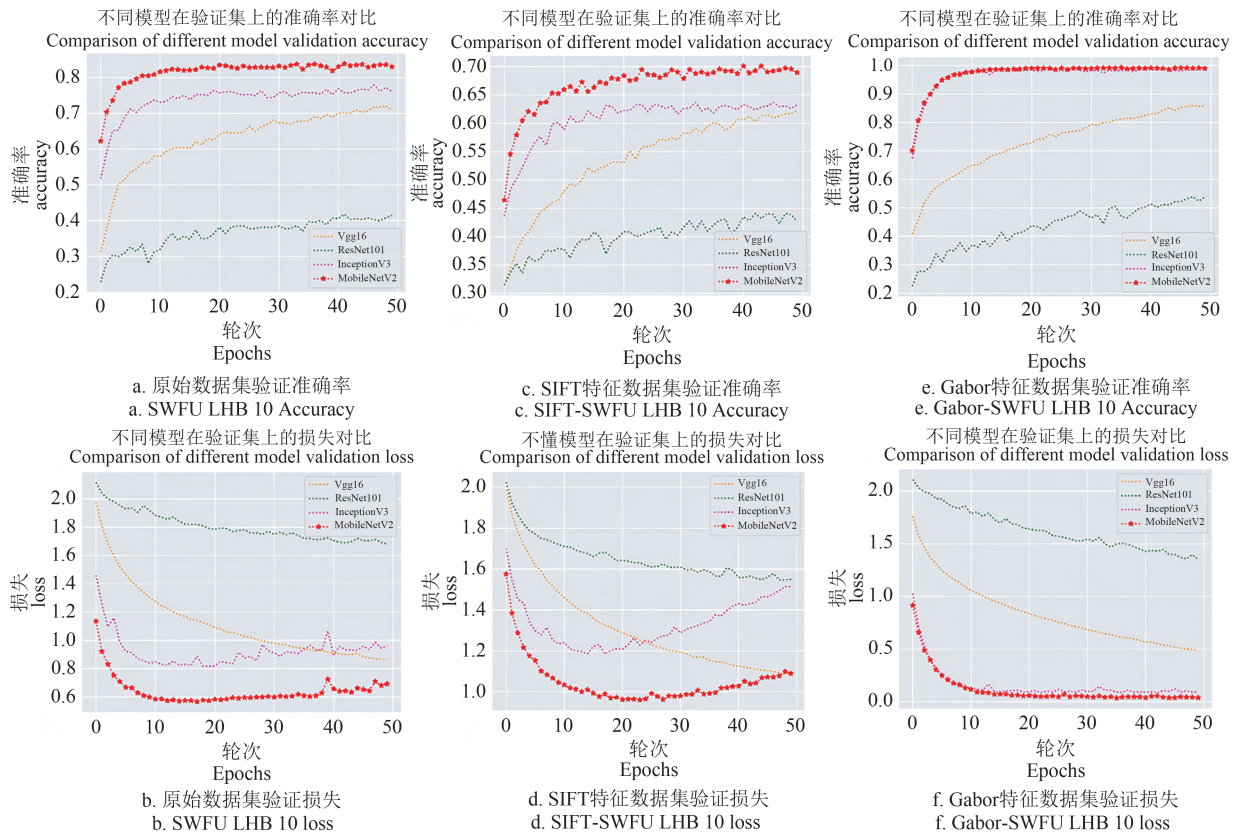


图5 不同数据集验证结果对比

Fig. 5 Comparison of validation results on different datasets

3 讨论

本文提出基于Gabor小波特征提取与轻量级MobileNetV2网络的天牛图像分类方法,在特征提取和模型训练方面均显著优于其他方法,识别准确率达98.94%。以往学者在天牛识别研究中多采用分子生物学手段^[7]或传统形态学方法^[8],依靠肉眼观察外部形态,并通过查阅相似种类文献进行比对鉴定^[8],此类方法不仅耗时费力、效率低下,且对鉴定人员的专业性要求较高。本文所提出的图像识别方法有效缓解了传统方法中对人工经验依赖较大、效率低等问题,实现了天牛种类的快速识别。Gabor特征在纹理与形态结构表达方面表现突出,识别效果显著优于LBP(61.93%)和GLCM(67.93%)方法;同时,MobileNetV2在Gabor-SWFU LHB 10数据集上取得了高达98.94%的识别准确率,充分验证了深度学习网络在天牛识别中的优势。相比之下,已有研究中采用融合SIFT与颜色特征并结合SVM分类器的方法,识别准确率仅为86.5%^[9],表明传统特征结合

浅层分类器在特征表达能力上存在明显局限。本文所构建的深度学习模型借助端到端的特征提取机制,结合Gabor特征的多尺度纹理建模能力,有效提升了图像识别性能。

本文的模型在识别准确率与效率方面均取得良好效果,但仍存在进一步优化的空间。MobileNetV2虽为轻量级网络,在计算资源受限场景下具备明显优势,但在处理更大规模数据集或复杂图像时,可能仍面临精度与效率之间的权衡。因此,模型的泛化能力仍有提升空间,以更好适应不同背景、光照及图像质量条件下的天牛图像识别任务。未来研究可从网络结构优化、训练策略改进等方面入手,以提升模型的鲁棒性和准确性。此外,本文选取的10种天牛在体色和外观特征上差异明显,图像区分度较高,识别难度相对较低,这在一定程度上限制了模型在物种形态相近或自然环境复杂背景下的泛化能力。因此,后续研究可进一步引入更多形态相近物种、不同发育阶段及自然采集条件下的图像数据,以全面验证模型的应用广度与实际推广

价值。

4 结论

本文提出了一种基于 Gabor 小波特征提取与轻量级 MobileNetV2 网络的天牛图像分类方法,有效解决了天牛图像的高效、准确的识别问题。通过对云南地区常见 10 种天牛的标本及自然背景图像进行数据采集、预处理、特征提取和模型构建,结果表明:Gabor 特征在纹理与形态结构表达方面明显优于传统的 LBP(准确率为 61.93%)和 GLCM(准确率为 67.93%)方法,能够更有效地提取天牛鞘翅的纹理和体表斑纹等关键识别特征; MobileNetV2 作为轻量级深度网络,在保证高识别精度的同时,具备更优的计算性能,其在 Gabor-SWFU LHB 10 数据集上,取得了 98.94% 的识别准确率、99.00% 的精度与召回率, F1-score 高达 98.80%。其整体性能优于 VGG16(准确率为 85.78%)、InceptionV3(准确率为 98.59%)和 ResNet101(准确率为 53.75%)等模型。综合对比不同特征提取方法与深度模型的识别效果可知, Gabor 小波对图像纹理特征的多尺度、多方向分析能力,是提升天牛图像识别精度的关键因素。此外,该方法在复杂自然背景下也具备良好的鲁棒性,为天牛野外监测、林业病虫害防控的实际应用提供了可靠的技术支撑。

参考文献

- [1] Linsley E G. Ecology of cerambycidae[J]. Annual Review of Entomology,1959,4(01):99-138.
- [2] 李金兰.重庆市天牛总科昆虫分类研究[D].重庆:重庆师范大学,2023.
- [3] 李丽莎.云南天牛[M].昆明:云南科技出版社,2009:3
- [4] 李丹丹.云南林地森林面积均居全国第二位[N/OL].昆明日报,2022-12-01(004)[2025-1-12].<https://kmb.kmzsc.com/>.
- [5] 刘梦盈.云南松对云南松小蠹危害的光谱响应及其受害监测研究[D].北京:中国林业科学研究院,2022.
- [6] 云南省林业和草原局.昆明林草原局推进林业有害生物防治工作[EB/OL].(2020-07-29)[2025-1-12].https://lcy.yn.gov.cn/html/2020/kunming_0729/57325.htm.
- [7] 谭亮魁,王文凯.生物技术在天牛分类中的应用[J].中国农学通报,2007(12):53-57.
- [8] 付甫永,司徒春南,路纪芳,等.贵州省核桃蛀干害虫白条天牛的分类特征分析研究[J].绿色科技,2016(17):81-83.
- [9] 满庆丽.天牛图像的特征提取和识别算法的研究[D].哈尔滨:东北林业大学,2013.
- [10] 夏令.天牛幼虫蛀木振动信号的降噪及特征识别[D].北京:北京交通大学,2022.
- [11] 慕君林,马博,王云飞,等.基于深度学习的农作物病虫害检测算法综述[J].农业机械学报,2023,54(S2):301-313.
- [12] 彭鑫.基于深度学习的农业害虫识别方法研究[D].吉林:吉林化工学院,2024.
- [13] 孙丰刚,王建丽,季英超,等.基于机器视觉的松林天牛远程智能监测系统[J].农业工程学报,2023,39(17):190-198.
- [14] Marcelja S. Mathematical description of the responses of simple cortical cells[J]. Journal of the Optical Society of America,1980,70(11):1297-1300.
- [15] Daugman J G. Two-dimensional spectral analysis of cortical receptive field profiles[J]. Vision Research, 1980,20(10):847-856.
- [16] 杨旺功,淮永建,张福泉.基于 Gabor 及深度神经网络的葡萄种子分类[J].电子科技大学学报,2020,49(01):131-138.
- [17] Hu X, Wang X, Meng F, et al. Gabor-CNN for object detection based on small samples[J]. Defence Technology,2020,16(6):1116-1129.
- [18] 魏祥坡,余旭初,谭熊,等. CNN 和三维 Gabor 滤波器的高光谱图像分类[J].计算机辅助设计与图形学学报,2020,32(01):90-98.
- [19] Kovac I, Marak P. Finger vein recognition: utilization of adaptive gabor filters in the enhancement stage combined with sift/surf-based feature extraction[J]. Signal, Image and Video Processing, 2023, 17(3): 635-641.
- [20] Imamura A, Arizymi N. Gabor filter incorporated CNN for compression[C]. 2021 36th International Conference on Image and Vision Computing New Zealand (IVCNZ). IEEE,2021:1-5.
- [21] 蒋心璐,陈天恩,王聪,等.农业害虫检测的深度学习算法综述[J].计算机工程与应用,2023,59(06):30-44.
- [22] 周爱明,马鹏鹏,席天宇,等.基于深度学习的蝴蝶科级标本图像自动识别[J].昆虫学报,2017(11):1339-1348.
- [23] 张洁.基于图像识别的农作物害虫诊断技术研究与应用[D].合肥:中国科学技术大学,2014.
- [24] Sandler M, Howard A, Zhu M, et al. Mobilenetv2:

- Inverted residuals and linear bottlenecks[C]. Proceedings of the IEEE conference on computer vision and pattern recognition, 2018:4510-4520.
- [25] 李国进,黄晓洁,李修华,等.采用轻量级网络MobileNetV2的酿酒葡萄检测模型[J].农业工程学报,2021,37(17):168-176.
- [26] 刘张,郭旭东,李胜男.基于MobileNetV2的小肠溃疡病灶图像识别[J].中国生物医学工程学报,2024,43(01):70-79.
- [27] 杨国亮,李放,朱晨,等.改进MobileNetV2网络在遥感影像场景分类中的应用[J].遥感信息,2020,35(01):1-8.
- [28] Su Z, Pietikainen M, Liu L. From Local Binary Patterns to Pixel Difference Networks for Efficient Visual Representation Learning[C]. Scandinavian Conference on Image Analysis. Cham: Springer Nature Switzerland,2023:138-155.
- [29] Iqbal N, Mumtaz R, Shafi U, et al. Gray level co-occurrence matrix(GLCM) texture based crop classification using low altitude remote sensing platforms[J]. PeerJ Computer Science,2021,7:e536.
- [30] Tang L, Ma S, Ma X, et al. Research on image matching of improved sift algorithm based on stability factor and feature descriptor simplification [J]. Applied Sciences,2022,12(17):8448.
- [31] Lee T S. Image representation using 2D Gabor wavel-ets[J]. IEEE Transactions on pattern analysis and machine intelligence,1996,18(10):959-971.
- [32] Ghiasi-Shirazi K. Learning 2D Gabor filters by infinite kernel learning regression[J]. Journal of Computational Mathematics and Data Science,2021, 1:100016.
- [33] Howard A G, Zhu M, Chen B, et al. Mobilenets: Efficient convolutional neural networks for mobile vision applications[J]. arXiv preprint arXiv: 1704.04861,2017:1-9.
- [34] Savargiv M, Masoumi B, Keyvanpour M R. A new random forest algorithm based on learning automata [J]. Computational Intelligence and Neuroscience, 2021(1):5572781.
- [35] Tarzanagh D A, Li Y, Thrapoulidis C, et al. Transformers as support vector machines[J]. arXiv preprint arXiv:2308.16898,2023:1-58.
- [36] Raghuvanshi S,Dhariwal S. The VGG16 Method Is a Powerful Tool for Detecting Brain Tumors Using Deep Learning Techniques[J]. Engineering Proceedings, 2023,59(1):46.
- [37] Szegedy C,Vanhoucke V,Ioffe S,et al. Rethinking the inception architecture for computer vision[C]. Proceedings of the IEEE conference on computer vision and pattern recognition,2016:2818-2826.
- [38] Zhang Q. A novel ResNet101 model based on dense dilated convolution for image classification[J]. SN Applied Sciences,2022,4:1-13.