

doi:10.6041/j.issn.1000-1298.2023.01.021

# 基于高光谱成像和 Att-BiGRU-RNN 的柑橘病叶分类

吴叶兰<sup>1</sup> 管慧宁<sup>1</sup> 廉小亲<sup>1</sup> 于重重<sup>1</sup> 廖禹<sup>2</sup>

(1. 北京工商大学中国轻工业工业互联网与大数据重点实验室, 北京 100048;

2. 江西省农业科学院农业工程研究所, 南昌 330200)

**摘要:** 为实现对柑橘叶片病虫药害种类的快速精准识别, 针对多种类柑橘病叶设计一种融合注意力机制(Attention mechanism)的双向门控循环单元–循环神经网络(Attention-bidirectional gate recurrent unit – recurrent nural network, Att-BiGRU-RNN)分类模型。该模型在编解码模块分别采用 BiGRU 和 RNN 结构, 能够利用高光谱数据前后波段光谱信息的关联性, 有效提取光谱信息的深层特征; 根据不同波段光谱信息的差异性引入注意力机制动态分配权重信息, 提高重要光谱特征对分类模型的贡献率, 提升模型的分类准确率。获取 6 类柑橘叶片高光谱信息, 构建实验样本集, 利用 Att-BiGRU-RNN、VGG16、SVM 和 XGBoost 分别建立柑橘病叶分类模型, Att-BiGRU-RNN 模型总体分类准确率(Overall accuracy, OA)平均可达 98.21%, 相较于其他 3 种模型分别提高 4.71、10.95、3.89 个百分点, 对光谱曲线重合度高的除草剂危害和煤烟病叶片的分类准确率有显著提升。实验结果表明, 深度学习方法可有效利用高光谱不同波段间的关联信息, 识别准确率较机器学习方法有大幅提高, 为柑橘病虫药害快速无损检测和防治提供了一种新方法。

**关键词:** 柑橘病叶; 高光谱成像; 深度学习; 注意力机制; 特征提取

中图分类号: O433.4; S436.661 文献标识码: A 文章编号: 1000-1298(2023)01-0216-08

OSID:



## Classification of Citrus Diseased Leaves Based on Hyperspectral and Att-BiGRU-RNN

WU Yelan<sup>1</sup> GUAN Huining<sup>1</sup> LIAN Xiaoqin<sup>1</sup> YU Chongchong<sup>1</sup> LIAO Yu<sup>2</sup>

(1. Key Laboratory of Internet and Big Data in Light Industry, Beijing Technology and Business University, Beijing 100048, China

2. Institute of Agricultural Engineering, Jiangxi Academy of Agricultural Sciences, Nanchang 330200, China)

**Abstract:** Citrus is widely cultivated in China and has many excellent varieties. There are many excellent varieties of citrus which are widely cultivated in China. However, citrus is susceptible to pest and disease infections during growth, which seriously affects the yield and quality of citrus. Common diseases include ulcer disease, deficiency disease and soot disease, etc. Insect pests include red spider and leaf miner moth, etc. Drug pests include herbicides and acaricides. The development of citrus industry is closely related to the control of diseases and insect pests. In order to realize the rapid and accurate identification of diseases and insect pests on citrus leaves, an Att-BiGRU-RNN classification model was proposed for multi species of citrus diseased leaves. The model adopted BiGRU and RNN structures in the encoding and decoding module, which can effectively extract the deep features of spectral information by using the correlation of spectral information in the front and back bands of hyperspectral images. According to the difference of spectral information of different bands, the attention mechanism was introduced to dynamically allocate weight information to improve the contribution of important spectral features to the classification model and enhance the classification accuracy of the model. Hyperspectral information of six types of citrus leaves was acquired to construct the experimental sample set, and Att-BiGRU-RNN, VGG16, SVM and XGBoost were used to establish classification models of citrus diseased leaves respectively. The overall accuracy (OA) of the Att-BiGRU-RNN model can reach 98.21% on average, which was 4.71 percentage points, 10.95 percentage points and 3.89 percentage points higher compared with that of the other three models respectively, and the recognition accuracy of herbicide and

收稿日期: 2022-10-07 修回日期: 2022-11-25

基金项目: 国家重点研发计划项目(2018YFC0807903)

作者简介: 吴叶兰(1970—), 女, 副教授, 主要从事智能信息处理、高光谱技术和机器人技术研究, E-mail: wuyel@th.btbu.edu.cn

soot disease with high spectral curve coincidence was significantly improved. The experimental results showed that the deep learning method can effectively use the correlation information between different hyperspectral bands, and the classification accuracy was greatly improved compared with the machine learning method, which provided a method for rapid non-destructive detection and prevention of citrus diseases and pests.

**Key words:** citrus diseased leaves; hyperspectral imaging; deep learning; attention mechanism; feature extraction

## 0 引言

柑橘在我国栽培面积广泛,优良品种繁多<sup>[1]</sup>,近10年来中国柑橘的产量涨幅达78%,已成为国内第一大水果。然而,柑橘在生长过程中容易受到病虫药害感染,严重影响柑橘的产量和质量。快速准确识别柑橘果树所遭受的病虫害种类,采取针对性的防治措施,对提高柑橘产量和品质,推动柑橘产业健康发展有着重要意义。传统的柑橘病虫药害检测方法主要有人工检测法和病理分析法,存在主观性强、成本高、破坏试样、效率低等问题,已无法满足科学的研究和生产的需要。

高光谱成像技术具有图谱合一、信息量大的特点<sup>[2-3]</sup>,可快速、无损检测样品内部结构和外部特征,已在农业工程领域得到广泛研究<sup>[4-8]</sup>。现阶段基于高光谱成像技术的植物病虫害诊断模型大多使用传统机器学习方法<sup>[9]</sup>。刘燕德等<sup>[10]</sup>以柑橘叶片为研究对象,结合极限学习机(Extreme learning machine, ELM)和最小二乘支持向量机(Least squares support vector machine, LS-SVM)构建柑桔黄龙病判别模型,可准确诊断柑橘黄龙病。邓小玲等<sup>[11]</sup>为识别柑橘黄龙病植株,分别使用极限梯度提升树(XGBoost)、逻辑回归和SVM等机器学习算法搭建模型,识别准确率均在93%以上。吴叶兰等<sup>[12]</sup>采用不同预处理和机器学习方法建模,实现了多种类柑橘病虫害检测,但除草剂危害和煤烟病叶片识别效果较差。现有研究证明,高光谱技术是植物病虫害检测的有效手段,但大多采用传统机器学习方法进行检测,通常需要数据预处理与特征提取,依赖人工经验,且特征提取后信息量有损失,导致模型精度难以提升。

深度学习是机器学习的分支,能有效提取复杂任务的高阶非线性特征,解决复杂的模式识别问题<sup>[13]</sup>,已在农作物目标检测、产量预测、病虫害识别及受害程度评估<sup>[14-17]</sup>中得到广泛应用。ABDULRIDHA等<sup>[18]</sup>将神经网络径向基函数用于柑橘溃疡病染病程度的检测,得到不同阶段染病叶片分级模型,结果表明,所建立的网络模型性能优于SVM等机器学习方法。苏鸿等<sup>[19]</sup>为提高柑橘重要

病症分类和病理检测效率,采用区域卷积神经网络对柑橘黄龙病、红蜘蛛感染和溃疡病等主要病症图像进行识别,平均识别准确率分别为95.30%、90.30%、99.10%。BARI等<sup>[20]</sup>使用Faster-RCNN对水稻患病叶片和健康叶片图像进行检测,识别准确率均在98%以上。黄敏等<sup>[21]</sup>利用高光谱成像技术和深度学习方法,建立了小麦种子品种识别的MS-3DCNN模型,识别准确率优于现有机器学习检测方法。上述研究表明,采用高光谱技术结合深度学习<sup>[22]</sup>为多种类柑橘病虫害识别提供了较好的理论基础和可行性方案。

本文利用深度学习挖掘光谱信息的深层特征,结合高光谱成像技术提出一种融合注意力机制(Attention mechanism)的编码器-解码器(Encoder-Decoder)模型Att-BiGRU-RNN。编解码器分别利用双向门控循环单元(Bidirectional gate recurrent unit, BiGRU)和循环神经网络(Recurrent neural network, RNN),处理光谱序列前后关联波段的特征,简化特征提取操作;引入注意力机制对每个光谱通道进行动态加权,加强重要光谱波段的权重,以提高不同种类叶片的分类精度,为多种类柑橘果树病虫药害识别提供理论依据与技术支持。

## 1 高光谱图像采集与深度学习模型构建

### 1.1 实验样本

实验样本采自江西省新余市柑橘果园,采摘时间为2019年2月、2020年10月、2022年3—4月,共759片叶片。其中,正常叶片102片、溃疡病叶片115片、除草剂危害叶片156片、红蜘蛛危害叶片121片、煤烟病叶片158片和缺素病叶片107片。

### 1.2 高光谱图像采集

采用美国SOC公司的SOC710VP高光谱成像系统采集高光谱图像,参数设置如下:光谱范围为350~1 050 nm,光谱分辨率为1.3 nm,光谱波段数为128,镜头类型为C-Mount,焦距可调。选用4个12 V卤素灯作为光源,亮度、角度可调。设定高光谱图像采集曝光时间为150 ms,物距为57.6 cm,扫描速度30行/s,32 s/cube,原始图像尺寸为696像素×520像素。图1为6类柑橘叶片高光谱图像样例。

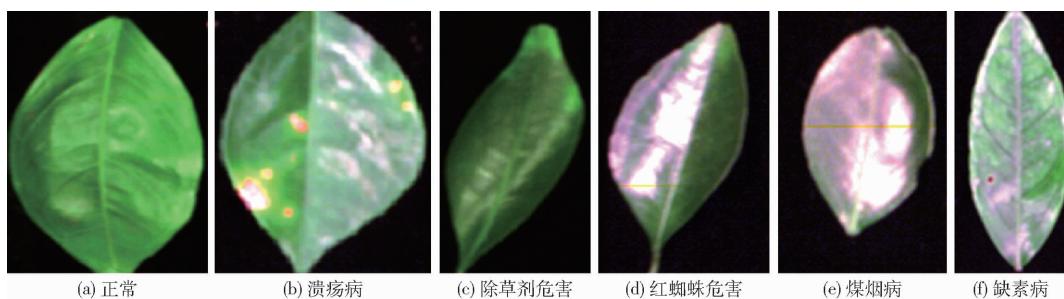


图 1 6类柑橘叶片高光谱图像样例

Fig. 1 Hyperspectral images of leaves of six citrus species

### 1.3 光谱信息提取

在 ENVI 中导入反射率 float 文件, 选择受噪声影响小的波长 478~900 nm 间(共 81 个波段)的高光谱图像用于后续数据处理与分析, 在叶片发病区提取  $5 \times 5$  的感兴趣区域(Region of interest, ROI), 将每个像素点的反射率作为光谱信息, 6 类柑橘叶片共提取 936 个 ROI, 得到  $23\,400 \times 81$  的柑橘叶片光谱数据集, 数据集每 1 行为 1 个像素点 81 个波段的光谱反射率值, 共有 23 400 条样本数据。

### 1.4 模型构建及评价

#### 1.4.1 柑橘叶片分类网络模型构建

Encoder – Decoder 模型最初用于自然语言处理, 近年来被大量用于时间序列预测, 是一种典型的序列到序列模型<sup>[23]</sup>。由于高光谱中不同波段的光谱信息本质上是一种序列数据, 本文提出了 Att – BiGRU – RNN 柑橘叶片分类模型, 网络架构如图 2 所示。编码模块采用 BiGRU 单元提取光谱序列  $X$  的特征信息, 得到特征光谱序列  $h_t$ ; 解码模块融合注意力机制, 获取不同波段光谱特征序列数据的动态权重, 对编码器各波段的隐藏状态  $h_t$  做加权平均, 得到动态加权后的光谱特征序列, 经过解码器隐藏层 RNN, 输出最终的特征序列  $S$ ; 最后经 softmax 函数得到预测标签  $Y$ 。

均, 得到动态加权后的光谱特征序列, 经过解码器隐藏层 RNN, 输出最终的特征序列  $S$ ; 最后经 softmax 函数得到预测标签  $Y$ 。

#### 1.4.2 编解码模块

双向门控循环单元(Gated recurrent unit, GRU)<sup>[24]</sup>是一种带有门控结构的 RNN, 内含更新门  $z$  和重置门  $r$ , 这种门结构能够在隐藏层中选择性地传递信息, 解决 RNN 中存在的梯度消失问题, 同时克服短时记忆等缺陷, 其计算过程为

$$z_t = \sigma(\mathbf{W}_z \mathbf{x}_t + \mathbf{U}_z \mathbf{h}_{t'} + \mathbf{b}_z) \quad (1)$$

$$r_t = \sigma(\mathbf{W}_r \mathbf{x}_t + \mathbf{U}_r \mathbf{h}_{t'} + \mathbf{b}_r) \quad (2)$$

$$\tilde{\mathbf{h}}_t = \tanh(\mathbf{W}_h \mathbf{x}_t + \mathbf{U}_h (\mathbf{r}_t \odot \mathbf{h}_{t'}) + \mathbf{b}_h) \quad (3)$$

$$\overrightarrow{\mathbf{h}}_t = (1 - z_t) \odot \mathbf{h}_{t'} + z_t \odot \tilde{\mathbf{h}}_t \quad (4)$$

式中  $\mathbf{W}, \mathbf{U}, \mathbf{b}$ —GRU 中更新门和重置门的参数矩阵和偏差,  $\mathbf{W} \in \mathbf{R}^{k \times n}$ ,  $\mathbf{U} \in \mathbf{R}^{k \times k}$ ,  $\mathbf{b} \in \mathbf{R}^k$

$\mathbf{x}_t$ —第  $t$  个波段的输入光谱信息

$\odot$ —Hadamard 乘积运算

$\mathbf{h}_t$ —第  $t$  个波段的前一波段隐藏层状态信息, 计算正向隐藏输出时为  $\mathbf{h}_{t-1}$ , 计算

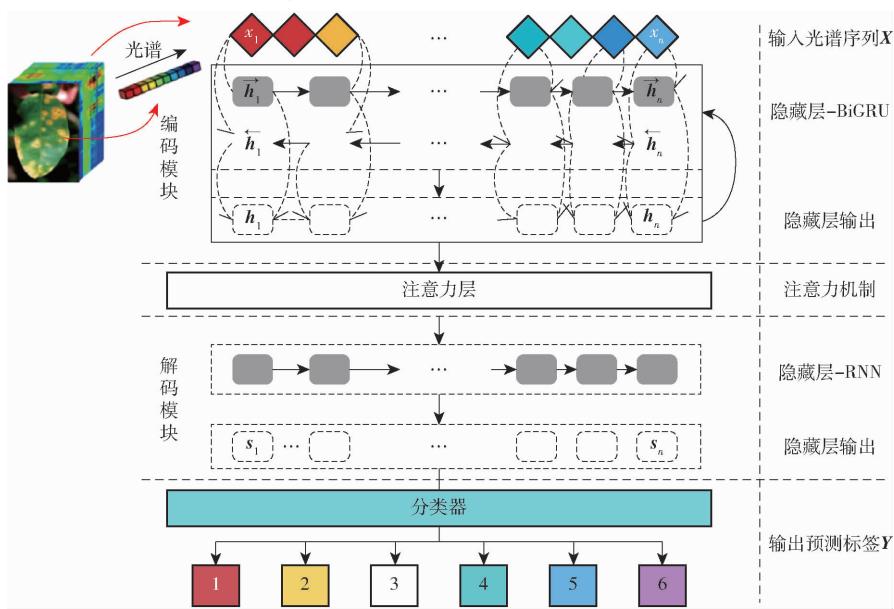


图 2 柑橘叶片分类网络架构图

Fig. 2 Citrus leaf classification network architecture

反向隐藏输出时为  $\mathbf{h}_{t+1}$

$\tilde{\mathbf{h}}_t$ —GRU 单元隐状态更新量

$\overleftarrow{\mathbf{h}}_t$ —第  $t$  个波段隐藏层状态输出信息, 计算正向隐藏输出时为  $\overrightarrow{\mathbf{h}}_t$ , 计算反向隐藏输出时为  $\overleftarrow{\mathbf{h}}_t$

$\mathbf{z}_t$ —更新门向量     $\mathbf{r}_t$ —重置门向量

$\sigma$ —Sigmoid 激活函数

$\tanh$ —双曲正切激活函数

本文的编码模块采用 BiGRU 提取光谱序列特征, 它由 2 个沿相反方向传播的 GRU 构成, 可为输出层同时提供双向的光谱序列信息。根据式(4)对输入序列分别计算正、反向隐藏状态的输出  $\overrightarrow{\mathbf{h}}_t$  和  $\overleftarrow{\mathbf{h}}_t$ , 将正、反向 GRU 的输出拼接, 得到最终的特征光谱序列  $\mathbf{h}_t$ 。

在解码模块中, 设计了融合注意力机制<sup>[25]</sup>的 RNN 结构。注意力机制的本质是对模型中特定部分进行重点关注并赋予高权重, 提高重要光谱波段对分类模型的贡献率, 进而实现模型优化和性能提升。图 3 为注意力机制结构, 根据不同类柑橘病叶光谱信息在不同波段上光谱特征的差异性, 注意力机制给每个光谱特征都输出权值  $a_{t,i}$ , 并自适应地给重要特征波段分配更高权重, 提高重要光谱波段对分类模型的贡献率。

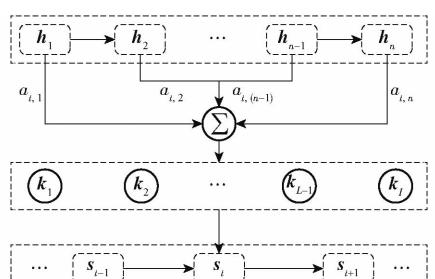


图 3 注意力机制结构示意图

Fig. 3 Structure diagram of attention mechanism

将图 3 中  $\mathbf{h}_t$  和  $a_{t,i}$  对应相乘并累加求和, 得到动态加权融合后的特征向量  $\mathbf{k}_t$ , 经过解码模块的隐藏层, 得到解码模块输出  $\mathbf{s}_t$ , 最后经过分类器得到预测标签  $\mathbf{Y}$ 。计算过程为

$$e_{t,i} = \mathbf{v}^T \tanh(\mathbf{U}_1 \mathbf{h}_t + \mathbf{U}_2 \mathbf{s}_{t-1} + \mathbf{b}_t) \quad (5)$$

$$a_{t,i} = \frac{\exp(e_{t,i})}{\sum_{i=1}^n \exp(e_{t,i})} \quad (6)$$

$$\mathbf{k}_t = \sum_{i=1}^n a_{t,i} \mathbf{h}_i \quad (7)$$

$$y_m = f(\mathbf{s}_t) \quad (8)$$

式中  $e_{t,i}$ —第  $t$  个波段和第  $i$  个波段的隐藏层相关程度

$\mathbf{v}, \mathbf{U}_1, \mathbf{U}_2$ —注意力机制权重系数矩阵,  $\mathbf{v} \in$

$\mathbf{R}^m, \mathbf{U}_1 \in \mathbf{R}^{m \times k}, \mathbf{U}_2 \in \mathbf{R}^{m \times m}$

$\mathbf{b}_t$ —偏置系数,  $\mathbf{b}_t \in \mathbf{R}^m$

$a_{t,i}$ —编码器第  $i$  个波段对解码器第  $t$  个波段的注意力分配系数

$n$ —光谱波段数

$f$ —分类器 softmax 分类函数

$y_m$ —预测标签

### 1.4.3 实验环境及模型评价

本文实验网络模型的处理器为 Intel(R) Core(TM) i7-6800K CPU, 频率 3.40 GHz, 内存为 16 GB, GPU 为 NVIDIA GeForce GTX 1080Ti, 开发环境为 Python 3.6, CUDA 10.0, Windows 10 64 位操作系统。表 1 给出了 Att-BiGRU-RNN 编码器解码器模型网络结构参数, 在固定网络结构参数的基础上, 使用自动机器学习 (AutoML) 开源工具包 NNI (Neural network intelligence) 寻求可变参数的最优值。选择自适应矩估计 (Adam) 优化器作为梯度更新规则。

表 1 Att-BiGRU-RNN 模型网络结构参数

Tab. 1 Att-BiGRU-RNN network structure

parameters

超参数	网络结构参数				可变参数		
	序列长度	输入维度	隐藏层尺寸	网络层数	批数	学习率	批量大小
数值	1	81	17	2	600	0.001	128

实验采用 Pytorch 深度学习框架, 以构建的柑橘叶片高光谱数据集为基础, 按照训练集和测试集的比例为 7:3 划分样本集, 对本文提出的网络模型进行训练及测试, 绘制混淆矩阵, 并计算反映模型性能的评价指标: 准确率 (Accuracy) 和 F1 值 (F1 score), F1 值是精确率 (Precision) 和召回率 (Recall) 的加权平均, 取值在 0~1 之间, 值越大表明模型越好。每次实验过程随机重复 5 次, 将 5 次实验结果的平均值作为最终结果。

## 2 结果与讨论

### 2.1 光谱特征分析

不同种类的柑橘叶片在各个波段范围内对光的吸收和反射程度不同, 在光谱曲线上呈现出有差异的波峰和波谷。6 类叶片样本的平均光谱曲线如图 4 所示。曲线的总体走势相似, 不同类型病叶的吸收峰在相同的波长区间内。由于病虫药害对叶片表面颜色和叶绿素含量的影响, 所以光谱曲线在波长 500 nm 和 680 nm 附近有 2 个强烈吸收带, 550 nm

附近呈现一个反射率峰,720 nm 后形成高反射率台阶,利用这些波段区间吸收峰峰值的差异可以诊断柑橘果树所受胁迫状态。

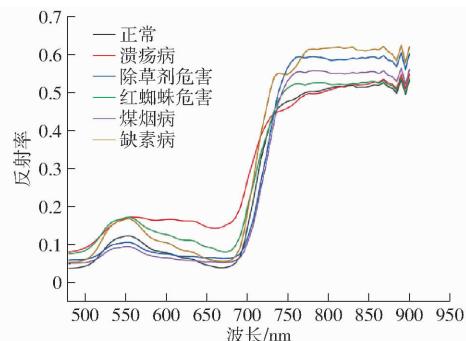


图 4 6 类叶片平均光谱曲线

Fig. 4 Average spectral curve of six types of leaves

从图 4 可以看出,在波长 550~750 nm 范围内,除草剂危害叶片和煤烟病叶片的光谱曲线高度重合,极易造成模型误判。图 5 为经主成分分析后的光谱样本分布散点图,可以看出,6 类叶片的光谱分布呈现出一定的聚类效果,其中除草剂危害和煤烟病叶片出现大范围重叠。因此,仅通过光谱分析难以区分不同种类的柑橘病叶,需要进一步建立模型对多种类柑橘病叶进行精准识别。

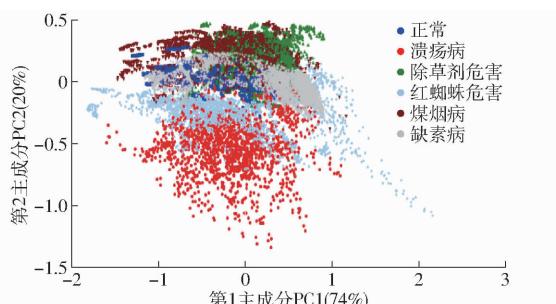


图 5 6 类叶片样本分布

Fig. 5 Distribution of six types of leaf samples

## 2.2 模型训练及测试结果

设置 RNN 和 BiRNN 编码器-解码器模型的网络结构参数与本文模型(Att-BiGRU-RNN)相同,分别建立 Att-BiGRU-RNN、BiRNN 和 RNN 的 Encoder-Decoder 模型,用损失值(Loss)和准确率的变化曲线评估模型性能。由图 6a 可知,整个训练过程中,Att-BiGRU-RNN 振荡幅度较小,曲线较平滑,在开始阶段损失值衰减最快,迭代 300 次后,BiRNN 和 RNN 模型的损失值趋于稳定,而 Att-BiGRU-RNN 模型的损失值仍有下降趋势,经 500 次迭代后趋于稳定,收敛于 0.08 左右。由图 6b 可知,在前 150 次迭代中,Att-BiGRU-RNN 和 BiRNN 模型的准确率均高于 RNN,经过 150 次迭代后,Att-BiGRU-RNN 的准确率高于 BiRNN 模型,这是由于 BiGRU 可充分利用光谱序列前后关联波

段的光谱信息,注意力机制可以给关键波段分配较大权重,更好地提取了光谱的深层特征,因此,Att-BiGRU-RNN 表现出了最佳性能。

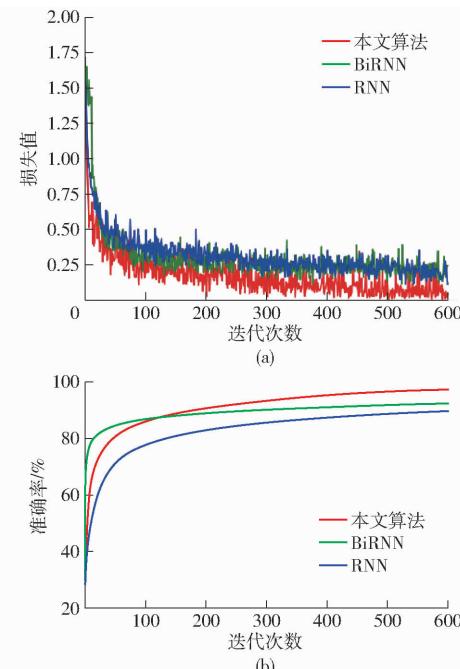


图 6 训练阶段损失值和准确率曲线

Fig. 6 Loss and accuracy curves in training phase

Att-BiGRU-RNN 在测试集上生成的混淆矩阵如图 7 所示,分析可知,柑橘正常叶、溃疡病叶、红蜘蛛危害叶和缺素病叶分类准确率均高于 98%。除草剂危害叶和煤烟病叶的分类准确率可达 94% 以上,优于传统机器学习方法,但仍有部分叶片被错分,说明所提深层光谱信息仍有相似性,后续研究需充分利用高光谱图像的图像特征信息,进一步提高 2 类叶片分类准确度。

	正常	溃疡病	除草剂危害	红蜘蛛危害	煤烟病	缺素病
正常	319	2	0	0	0	1
溃疡病	1	342	0	0	0	0
除草剂危害	0	0	608	0	72	0
红蜘蛛危害	0	0	1	529	0	0
煤烟病	0	0	10	0	737	0
缺素病	0	0	0	0	0	746
预测标签	正常	溃疡病	除草剂危害	红蜘蛛危害	煤烟病	缺素病

图 7 本文模型在测试集上生成的混淆矩阵

Fig. 7 Confusion matrix generated by proposed model on test set

## 2.3 不同模型结果对比分析

为客观评估本文所提方法,基于相同数据集,综

合考虑模型总体分类准确率(Overall accuracy, OA)和F1值,将Att-BiGRU-RNN与深度学习模型VGG16和机器学习模型Origin-CARS-SVM、MF-FS-XGBoost的分类效果进行对比,结果如图8和表2所示,其中Origin-CARS-SVM和MF-FS-XGBoost模型数据来源于文献[12]。

分析可知,相较于机器学习模型SVM和XGBoost,Att-BiGRU-RNN对各类叶片的识别准确率均在94%以上,针对难以区分的除草剂危害和煤烟病叶片,准确率可提升14.31个百分点以上,最高可提升21.81个百分点,Att-BiGRU-RNN的OA最高可提升10.95个百分点,F1值最高可提升10.09个百分点,这是由于机器学习方法的特征提取依赖于人工经验,模型分类效果主要由人工提取

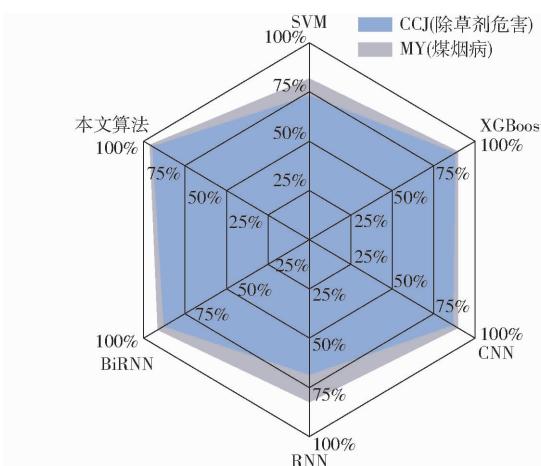


图8 除草剂危害和煤烟病分类结果对比

Fig. 8 Comparison of classification results of herbicide  
harm and soot disease

表2 不同分类方法分类结果对比

Tab. 2 Comparison of classification results of different classification methods

%

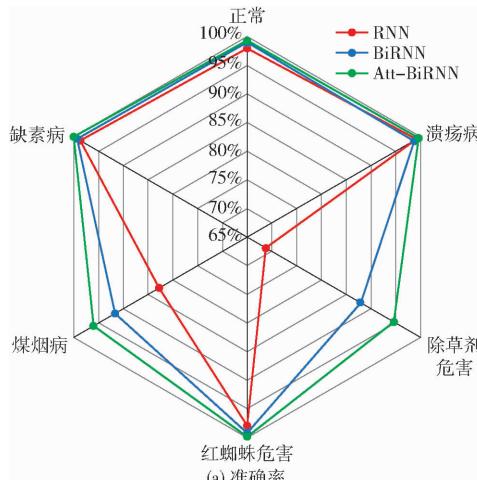
方法	模型	识别准确率						总体 准确率	F1值
		正常	溃疡病	除草剂危害	红蜘蛛危害	煤烟病	缺素病		
其他方法	Origin-CARS-SVM	100	99.35	72.80	98.45	81.66	99.03	87.26	86.92
	MF-FS-XGBoost	94.35	100	88.33	97.51	89.94	99.81	94.32	94.77
	VGG16	99.01	99.12	90.03	99.31	89.27	100	93.50	92.15
本文方法	Att-BiGRU-RNN	99.38	99.62	94.61	99.91	95.97	100	98.21	97.01

的浅层特征决定,这些特征不能有效表达光谱序列的关联性和深层信息,使模型分类性能受到限制。深度学习方法不需要对光谱数据进行预处理,可提取深层光谱特征,具有更强的表征和泛化能力。将本文模型与VGG16相比,2种模型对正常叶、溃疡病叶、红蜘蛛危害叶和缺素病叶的准确率均在99%以上,但本文模型对于除草剂危害和煤烟病的识别效果明显优于VGG16,总体识别准确率提高4.71个百分点,召回率提高4.86个百分点。这是因为高光谱数据本质上是一类序列数据,BiGRU适用于分

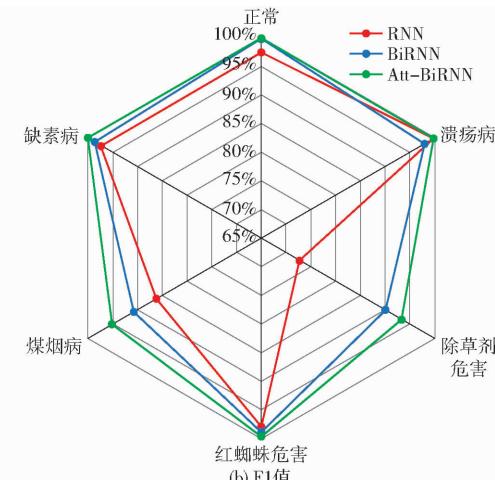
析序列数据,避免了VGG16模型将光谱数据看作是无序高维向量进行处理的问题。

## 2.4 消融实验

为进一步验证注意力机制对各类叶片分类准确率的影响,本文进行了消融实验。训练集5次实验结果的平均值如图9所示。可以看出,引入注意力机制后各类叶片的分类准确率和F1值均有提高。对于光谱曲线重合度较高的除草剂危害和煤烟病叶片,本文模型与RNN相比识别准确率分别提高25.78个百分点和13.19个百分点,与BiRNN相比



(a) 准确率



(b) F1值

图9 消融实验对比结果

Fig. 9 Ablation experiment comparison results

识别准确率分别提高 6.75 个百分点和 4.34 个百分点, F1 值也有相同程度提高。BiGRU 适用于分析序列数据, 可充分利用光谱序列前后关联波段的光谱信息, 促进梯度传播, 解决了 RNN 和 BiRNN 中存在的单向传输、梯度消失和短时记忆等问题。同时, 注意力机制可以给关键波段分配较大权重, 充分提取光谱信息的深层特征, 提高光谱特征相似叶片的分类准确率, 提升模型整体性能。

### 3 结论

(1) 为解决机器学习方法建立柑橘病叶分类模型时, 高光谱数据预处理过程复杂、未有效利用前后关联波段光谱信息等问题, 提出了 Att-BiGRU-RNN 模型, 分别在编解码模块采用 BiGRU 和 RNN 对光谱序列信息进行处理, 引入注意力机制, 提高重要光谱波段对分类模型的贡献率, 模型总体分类准确率

达 98.21%, 对各类叶片识别准确率均在 94% 以上。

(2) 在模型中融合注意力机制, 根据不同种类柑橘病叶光谱信息在不同波段上光谱特征的差异性, 自适应地给重要光谱波段分配更高权重, 提高重要光谱波段对分类模型的贡献率。与 VGG16、SVM、XGBoost 相比, 光谱曲线高度重合的除草剂危害和煤烟病叶片识别准确率得到显著提升, Att-BiGRU-RNN 模型综合性能最优。

(3) 针对卷积神经网络难以处理光谱序列数据的问题, Att-BiGRU-RNN 模型有效利用高光谱数据的序列性, 充分提取光谱特征的深层信息, 与 VGG16 相比总体识别准确率提高 4.71 个百分点。同时解决了传统机器学习方法因人工特征工程导致的光谱特征相似叶片分类准确率难以提升的问题, 总体识别准确率相较于 SVM 和 XGBoost 分别提高 10.95 个百分点和 3.89 个百分点。

### 参 考 文 献

- [1] 岳学军, 凌康杰, 王林惠, 等. 基于高光谱和深度迁移学习的柑橘叶片钾含量反演[J]. 农业机械学报, 2019, 50(3): 186–195.  
YUE Xuejun, LING Kangjie, WANG Linhui, et al. Inversion of potassium content for citrus leaves based on hyperspectral and deep transfer learning[J]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(3): 186–195. (in Chinese)
- [2] MANIFOLD B, MEN S, HU R, et al. A versatile deep learning architecture for classification and label-free prediction of hyperspectral images[J]. Nature Machine Intelligence, 2021, 3(4): 306–315.
- [3] ZHOU X, SUN J, TIAN Y, et al. Development of deep learning method for lead content prediction of lettuce leaf using hyperspectral[J]. International Journal of Remote Sensing, 2020, 41(6): 2263–2276.
- [4] MORSIER F D, BORGEAUD M, GASS V, et al. Kernel low-rank and sparse graph for unsupervised and semi-supervised classification of hyperspectral images[J]. IEEE Transactions on Geoscience & Remote Sensing, 2016, 54(6): 3410–3420.
- [5] 程权, 杨方, 王丹红, 等. 近红外光谱技术对闽南乌龙茶品种的识别研究[J]. 光谱学与光谱分析, 2014, 34(3): 656–659.  
CHENG Quan, YANG Fang, WANG Danhong, et al. Discrimination of Minnan oolong tea varieties by NIR spectroscopy[J]. Spectroscopy and Spectral Analysis, 2014, 34(3): 656–659. (in Chinese)
- [6] 宋余庆, 谢熹, 刘哲, 等. 基于多层 EESP 深度学习模型的农作物病虫害识别方法[J]. 农业机械学报, 2020, 51(8): 196–202.  
SONG Yuqing, XIE Xi, LIU Zhe, et al. Crop pests and diseases recognition method based on multi-level EESP model[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(8): 196–202. (in Chinese)
- [7] 高超, 赵玥, 赵燕东. 基于茎干含水率的紫薇病虫害等级早期诊断方法[J]. 农业机械学报, 2018, 49(11): 189–194.  
GAO Chao, ZHAO Yue, ZHAO Yandong. Early diagnosis method of disease and pest level on *Lagerstroemia indica* based on stem water content[J]. Transactions of the Chinese Society for Agricultural Machinery, 2018, 49(11): 189–194. (in Chinese)
- [8] NETTLETON D F, KATSANTONIS D, KALAITZIDIS A, et al. Predicting rice blast disease: machine learning versus process-based models[J]. BMC Bioinformatics, 2019, 20(1): 1–16.
- [9] 翟肇裕, 曹益飞, 徐焕良, 等. 农作物病虫害识别关键技术研究综述[J]. 农业机械学报, 2021, 52(7): 1–18.  
Zhai Zhaoyu, CAO Yifei, XU Huanliang, et al. Review of key techniques for crop disease and pest detection[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(7): 1–18. (in Chinese)
- [10] 刘燕德, 肖怀春, 孙旭东, 等. 柑桔叶片黄龙病光谱特征选择及检测模型[J]. 农业工程学报, 2018, 34(3): 180–187.  
LIU Yande, XIAO Huaichun, SUN Xudong, et al. Spectral feature selection and discriminant model building for citrus leaf Huanglongbing[J]. Transactions of the CSAE, 2018, 34(3): 180–187. (in Chinese)
- [11] 邓小玲, 曾国亮, 朱梓豪, 等. 基于无人机高光谱遥感的柑橘患病植株分类与特征波段提取[J]. 华南农业大学学报, 2020, 41(6): 100–108.  
DENG Xiaoling, ZENG Guoliang, ZHU Zihao, et al. Classification and feature band extraction of diseased citrus plants based on UAV hyperspectral remote sensing[J]. Journal of South China Agricultural University, 2020, 41(6): 100–108. (in Chinese)
- [12] 吴叶兰, 管慧宁, 廉小亲, 等. 高光谱成像的多种类柑橘病虫药害叶片检测方法研究[J]. 光谱学与光谱分析, 2022, 42(8): 2397–2402.  
WU Yelan, GUAN Huining, LIAN Xiaoqin, et al. Study on detection method of leaves with various citrus pests and diseases by hyperspectral imaging[J]. Spectroscopy and Spectral Analysis, 2022, 42(8): 2397–2402. (in Chinese)

- [13] KAMARUDIN J A M, ABDULLAH A, SALLEHUDDIN R. A review of deep learning architectures and their application [C] // 17th Asia Simulation Conference, 2017; 7522.
- [14] 刘媛媛, 张凡, 师琪, 等. 基于高光谱和集成学习的库尔勒香梨黑斑病潜育期诊断 [J]. 农业机械学报, 2022, 53(6): 295–303.  
LIU Yuanyuan, ZHANG Fan, SHI Qi, et al. Diagnosis of Korla pear black spot disease in incubation period based on hyperspectral imaging and ensemble learning algorithm [J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(6): 295–303. (in Chinese)
- [15] 孙红, 李松, 李民赞, 等. 农业信息成像感知与深度学习应用研究进展 [J]. 农业机械学报, 2020, 51(5): 1–17.  
SUN Hong, LI Song, LI Minzan, et al. Research progress of image sensing and deep learning in agriculture [J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(5): 1–17. (in Chinese)
- [16] 郭祥云, 台海江. 深度学习在大田种植中的应用及展望 [J]. 中国农业大学学报, 2019, 24(1): 119–129.  
GUO Xiangyun, TAI Haijiang. Current situation and prospect of deep learning application in field planting [J]. Journal of China Agricultural University, 2019, 24(1): 119–129. (in Chinese)
- [17] 任志尚, 彭慧慧, 贺壮壮, 等. 基于高光谱成像技术的面条中马铃薯全粉含量检测 [J]. 农业机械学报, 2020, 51(增刊2): 466–470, 506.  
REN Zhishang, PENG Huihui, HE Zhuangzhuang, et al. Detection of potato powder addition in noodles based on hyperspectral imaging [J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(Supp. 2): 466–470, 506. (in Chinese)
- [18] ABDULRIDHA J, BATUMAN O, AMPATZIDIS Y. UAV-based remote sensing technique to detect citrus canker disease utilizing hyperspectral imaging and machine learning [J]. Remote Sensing, 2019, 11(11): 1373.
- [19] 苏鸿, 温国泉, 谢玮, 等. 基于区域卷积神经网络模型的广西柑橘病虫害识别方法研究 [J]. 西南农业学报, 2020, 33(4): 805–810.  
SU Hong, WEN Guoquan, XIE Wei, et al. Research on citrus pest and disease recognition method in Guangxi based on regional convolutional neural network model [J]. Southwest China Journal of Agricultural Sciences, 2020, 33(4): 805–810. (in Chinese)
- [20] BARI B S, ISLAM N, RASHID M, et al. A real-time approach of diagnosing rice leaf disease using deep learning-based Faster R-CNN framework [J]. PeerJ Computer Science, 2021, 432(7): 1–27.
- [21] 黄敏, 夏超, 朱启兵, 等. 融合高光谱图像技术与MS-3DCNN的小麦种子品种识别模型 [J]. 农业工程学报, 2021, 37(18): 153–160.  
HUANG Min, XIA Chao, ZHU Qibing, et al. Recognizing wheat seed varieties using hyperspectral imaging technology combined with multi-scale 3D convolution neural network [J]. Transactions of the CSAE, 2021, 37(18): 153–160. (in Chinese)
- [22] 张号连, 李映, 姜晔楠. 深度学习在高光谱图像分类领域的研究现状与展望 [J]. 自动化学报, 2018, 44(6): 961–977.  
ZHANG Haokui, LI Ying, JIANG Yenan. Deep learning for hyperspectral imagery classification: the state of the art and prospects [J]. Acta Automatica Sinica, 2018, 44(6): 961–977. (in Chinese)
- [23] HACHAJ T, STOLINSKA A, ANDRZEJEWSKA M, et al. Deep convolutional symmetric encoder-decoder neural networks to predict students' visual attention [J]. Symmetry, 2021, 13(12): 13122246.
- [24] TREISMAN A M, GELADE G. A feature-integration theory of attention [J]. Cognitive Psychology, 1980, 12(1): 97–136.
- [25] TANG Y, HUANG Y, WU Z, et al. Question detection from acoustic features using recurrent neural network with gated recurrent unit [C] // IEEE International Conference on Acoustics, Speech and Signal Processing. IEEE, 2016: 6125–6129.

(上接第 204 页)

- [24] DESAI M, SHAH M. An anatomization on breast cancer detection and diagnosis employing multi-layer perceptron neural network (MLP) and convolutional neural network (CNN) [J]. Clinical EHealth, 2021, 4: 1–11.
- [25] 尹柯, 巴文娟, 汤敏, 等. 多层感知器模型预测纯磨玻璃结节肺腺癌浸润程度 [J]. 中国医学影像技术, 2020, 36(11): 1652–1656.  
YIN Ke, BA Wenjuan, TANG Min, et al. Multilayer perceptron model in predicting infiltration degree of pure ground glass opacity lung adenocarcinoma [J]. Chinese Journal of Medical Imaging Technology, 2020, 36(11): 1652–1656. (in Chinese)
- [26] 王德广, 黄盈朵. 基于 SVM-MLP 的乳腺癌预测 [J]. 微型电脑应用, 2022, 38(1): 130–133, 138.  
WANG Deguang, HUANG Yingduo. Prediction of breast cancer based on SVM-MLP [J]. Microcomputer Applications, 2022, 38(1): 130–133, 138. (in Chinese)
- [27] 牛迪. 基于自注意力机制的多特征融合槽抽取模型 [J]. 南京理工大学学报, 2022, 46(1): 69–75.  
NIU Di. Multidimensional features slot filling model based on self-attention mechanism [J]. Journal of Nanjing University of Science and Technology, 2022, 46(1): 69–75. (in Chinese)
- [28] 韩旭, 赵春江, 吴华瑞, 等. 基于注意力机制及多尺度特征融合的番茄叶片缺素图像分类方法 [J]. 农业工程学报, 2021, 37(17): 177–188.  
HAN Xu, ZHAO Chunjiang, WU Huarui, et al. Image classification method for tomato leaf deficient nutrient elements based on attention mechanism and multi-scale feature fusion [J]. Transactions of the CSAE, 2021, 37(17): 177–188. (in Chinese)