

高光谱成像结合 BiTCN-SA 的马铃薯晚疫病早期识别

罗祖升¹, 刘雨琛¹, 王晓丹², 张巧杰^{1*}

1. 北京信息科技大学自动化学院, 北京 100192

2. 中国农业大学植物保护学院, 北京 100193

摘要: 及早识别晚疫病是控制马铃薯晚疫病发展的关键, 为充分利用高光谱数据波段间特征信息, 提高模型对马铃薯晚疫病早期识别的精度, 本文提出一种基于双向时间卷积网络(BiTCN)融合自注意力机制(SA)的马铃薯晚疫病早期识别模型(BiTCN-SA)。BiTCN通过正向和反向卷积支路捕捉波段间相关性特征, 充分利用前后波段的关联性; 自注意力机制动态分配不同波段的重要性权重, 提高关键波段对模型分类的贡献度。BiTCN-SA模型将自注意力与BiTCN相融合, 在双向上实现局部卷积特征与全局注意力权重的结合, 实现双重特征提取, 提高模型识别精度。采集3个等级(健康、无症状期、症状初期)的叶片高光谱数据并建模分析, 通过对比SVM、RF等机器学习方法和CNN、LSTM、TCN、BiTCN等深度学习方法, 以验证本文模型优越性。结果表明, BiTCN-SA模型的收敛速度比单一TCN和BiTCN更快, 且模型精度显著提高, 比其他机器学习和深度学习方法, 具备更强大的特征提取能力, 总体准确率达到98%, 且对无症状期的病叶识别率达到96%。该方法充分利用高光谱波段间的深层信息, 且模型识别率相比于其他机器学习和深度学习方法有大幅提高, 为马铃薯晚疫病早期预警和防治提供技术支持。

关键词: 马铃薯晚疫病; 高光谱成像; 早期识别; 双向时间卷积网络; 自注意力机制; 特征提取

中图分类号: O433.4

文献标识码: A

文章编号: 1000-2324(2026)01-0056-10

Early Identification of Potato Late Blight Using Hyperspectral Imaging Combined with BiTCN-SA

LUO Zu-sheng¹, LIU Yu-chen¹, WANG Xiao-dan², ZHANG Qiao-jie^{1*}

1. College of Automation/Beijing Information Science and Technology University, Beijing 100192, China

2. College of Plant Protection/China Agricultural University, Beijing 100193, China

Abstract: Early identification of potato late blight is crucial for controlling its development. To fully utilize the inter-band characteristic information of hyperspectral data and improve the accuracy of models in the early identification of potato late blight, this study proposes a potato late blight early identification model (BiTCN-SA) based on a Bidirectional Temporal Convolutional Network (BiTCN) fused with a Self-Attention (SA) mechanism. The BiTCN captures inter-band correlation features through forward and backward convolution branches, and fully exploits the associations between preceding and subsequent bands. The self-attention mechanism dynamically assigns importance weights to different bands, enhancing the contribution of key bands to model classification. The BiTCN-SA model integrates self-attention with BiTCN to achieve a combination of local convolutional features and global attention weights in both directions, realizing dual feature extraction and improving the model's identification accuracy. This study collects hyperspectral potato leaf data from three stages (healthy, asymptomatic, and early symptomatic), conducts modeling and analysis. It verifies the superiority of the proposed model by comparing machine learning methods such as SVM and RF, and deep learning models including CNN, LSTM, TCN, and BiTCN. The results show that the BiTCN-SA model converges faster than standalone TCN and BiTCN models, with significantly improved accuracy. It demonstrates stronger feature extraction capability than other machine learning and deep learning methods, achieving an overall accuracy of 98% and an identification rate of 96% for asymptomatic diseased leaves. This method fully utilizes deep inter-band information from hyperspectral data, and its identification rate shows substantial improvement over other machine learning and deep learning methods, providing technical support for early warning and control of potato late blight.

Keywords: Potato late blight; hyperspectral imaging; early identification; bidirectional temporal convolutional network; self-attention mechanism; feature extraction

收稿日期: 2025-03-17

修回日期: 2025-12-28

基金项目: 科技创新2030-“新一代人工智能”重大项目(2021ZD0113603)

第1作者简介: 罗祖升(2000-), 男, 硕士研究生, 研究方向: 高光谱数据分析。E-mail: uhenguo@163.com

*通讯作者: Author for correspondence. E-mail: qiaojiezhang@163.com

马铃薯是全球第四大重要的粮食作物,我国是世界上马铃薯种植面积最大的国家,而由致病疫霉引起的马铃薯晚疫病是一种毁灭性病害^[1],其爆发性强、蔓延速度快^[2],严重威胁我国粮食安全。

目前传统病害识别方法主要有人工判断和理化检测两种,人工判断通过肉眼无法诊断早期的无症状患病叶片;理化检测步骤繁琐、专业性要求高且残留物污染环境^[3]。如果能在早期有效识别出晚疫病并及时采取防治措施是控制马铃薯晚疫病发展的关键。高光谱成像技术融合了光谱与图像信息,能够同时获取植物的内外部特征数据,可快速、无损地检测植物病害,在植物病害的预警与识别方面具有广泛的应用价值^[4]。高光谱成像技术也面临一些挑战,由于高光谱数据波段较多,其中包含的大量冗余和共线性数据会影响建模精度,需要进行复杂的数据处理和分析。然而传统建模方法大多数采用机器学习方法如支持向量机(SVM)^[5]、随机森林(RF)^[6]等,其建模前往往需要经过多种预处理方法去除噪声,特征提取方法去除冗余,如竞争性自适应加权采样(CARS)^[7]、遗传算法(GA)、连续投影算法(SPA)^[8]等,通过这些方法组合建立多种模型,最后对比建模结果选择最佳模型。其建模过程繁琐,且有光谱信息损失,不能充分利用光谱深层信息,导致模型精度难以提升。

深度学习模型在处理光谱序列和复杂特征方面具有出色的效果^[9-11]。魏雷等人^[12]为解决高光谱数据特征维度高、模型精度易受降维方法影响等问题,构建了一种嵌入点积注意力机制的双向循环神经网络模型(AE-BiRNN)用于片烟的含水率预测。邓昀^[13]等人提出了一种改进时间卷积网络模型(SATCN)用于红壤有机质高光谱预测。吴叶兰等人^[14]设计了一种融合注意力机制的双向门控循环单元-循环神经网络分类模型(Att-BiGRU-RNN)结合高光谱成像技术用于柑橘叶片病虫害药害的种类识别。徐胜勇等人^[15]提出一种基于图谱特征融合的西瓜氮磷钾含量深度学习检测方法,采用自注意力机制-双向长短时记忆网络(Self-Attention-BiLSTM)构建了多种元素含量的预测模型。以上研究都取得了良好的结果,研究表明,深度学习结合高光谱成像技术具有巨大潜力^[16]。现有马铃薯晚疫病早期

识别和深度学习的研究仍较少,且依赖于生化信息^[17,18]。

本文以马铃薯叶片为研究对象,利用时间卷积充分挖掘高光谱波段之间的相关信息,提出一种基于双向时间卷积网络(bidirectional temporal convolution network, BiTCN)融合自注意力机制(Self-Attention)的用于马铃薯晚疫病的早期识别(BiTCN-SA), BiTCN-SA通过双向结构和因果膨胀卷积,提取波段间多尺度特征,充分利用前后波段的关联性,引入自注意力机制提高关键波段的重要性,通过与多种机器学习和深度学习对比,验证所提模型的优越性,为马铃薯的病情防控和种植生产提供理论基础和有力支持。

1 实验与方法

1.1 样品培育

实验使用的马铃薯叶片样品来自于中国农业大学植保学院,采集健康良好的马铃薯叶片样品若干,将其分为对照组和实验组,对照组不进行处理,对实验组接种致病疫霉,进行为期7 d的连续培养。接种和培育方式为将孢子悬浮液接种于叶片背面二级叶脉之间,每片叶子共4个接种点,每个接种点10 uL,接种完成之后,将叶片样本放入密闭的保湿盒中,再将其放入人工气候室,在温度为18 °C,相对湿度≥80%,每天16 h光照和8 h黑暗培养的条件下培养。接种0~7 d的马铃薯叶片变化如图1所示,其中第0 d为健康叶片。本文旨在研究晚疫病的早期识别,因此只选择0~3 d的叶片作为实验对象,由于第1 d叶片未被真正侵染,因此做如下分级:第0 d为健康(0级),第2 d为无症状期(1级),第3 d为症状初期(2级),共分为3个等级。




图1 0到7 d接种叶片变化

Fig. 1 Changes in inoculated leaves from 0 to 7 days

1.2 高光谱图像采集

实验设计的高光谱采集平台如图2所示,包括高光谱相机(GaiaField-V10,江苏双利合谱科技有限公司)、两个80 w 卤素灯、一个翻拍架(可调节高度)以及计算机,整个采集过程在暗室中

进行。高光谱相机空间分辨率为696×775像素,光谱分辨率为2.8 nm,光谱范围为400~1 000 nm,共256个波段。对应3个等级,分别采集0 d,第2 d,第3 d叶片的高光谱图像360张,每个等级120张。




图2 高光谱采集平台
Fig. 2 Hyperspectral acquisition platform

为消除暗电流及光照不均导致的干扰,需要对采集的原始图像进行黑白校正。先拍摄白色校准板得到白板图像数据,然后盖上镜头盖,采集暗背景图像数据。校正公式如下:

$$R = \frac{R_i - R_d}{R_w - R_d} \quad (1)$$

式中: R 为校准后的高光谱图像, R_i 为原始高光谱图像, R_w 为白板图像, R_d 为暗背景图像。

将整个叶片作为感兴趣区域,通过ENVI软件提取其平均光谱作为该叶片样本的光谱数据。由于提取的光谱曲线两端的噪声较大,取波段范围450~950 nm作为有效数据(203个波段),3个等级共提取360条原始光谱曲线。深度学习需要大量样本数据进行参数训练,由于受到叶片数量和采集设备限制,故本文采用数据增强增加样本量,通过高斯噪声注入(标准差 σ 为0.01~0.05)和光谱平移(左右平移0~3个波长点)的方式^[19]将360条原始光谱曲线按各等级等比扩充至3 600条。

1.3 BiTCN-SA模型构建

高光谱数据中的光谱数据本质上是一种序

列数据,本文提出一种基于双向时域卷积网络(Bi-directional Temporal Convolution Network, BiTCN)融合自注意力机制(Self-Attention)的马铃薯晚疫病早期识别模型(BiTCN-SA),将自注意力机制融入到BiTCN的正向支路和反向支路中,充分提取双向关键信息,提高BiTCN的全局特征提取能力,其结构如图3所示,包括序列输入层、融合自注意力机制的双向时间卷积网络层(BiTCN-SA)、全连接层、softmax层和输出层。

1.3.1 双向时域卷积网络模块 时间卷积网络(TCN)^[20]由BAI等人于2018年提出,改进了传统卷积神经网络(Convolutional Neural Networks, CNN),广泛应用于金融、发电和气象等领域时序预测^[21-23]。TCN通过因果卷积防止信息泄漏,膨胀卷积扩展感受野,残差连接防止梯度消失和过拟合问题,并具备并行计算、高效训练和长时依赖建模能力。对于一维数据 $[X_0, X_1, \dots, X_t, X_{t+1}]$,经过因果卷积后,第 t 时刻的输出 y_t 仅依赖于上一层中 t 时刻及其之前的输入值,如式(2)所示,其中, f 为因果卷积核变换。

$$y_t = f(X_0, X_1, \dots, X_t, X_{t+1}) \quad (2)$$

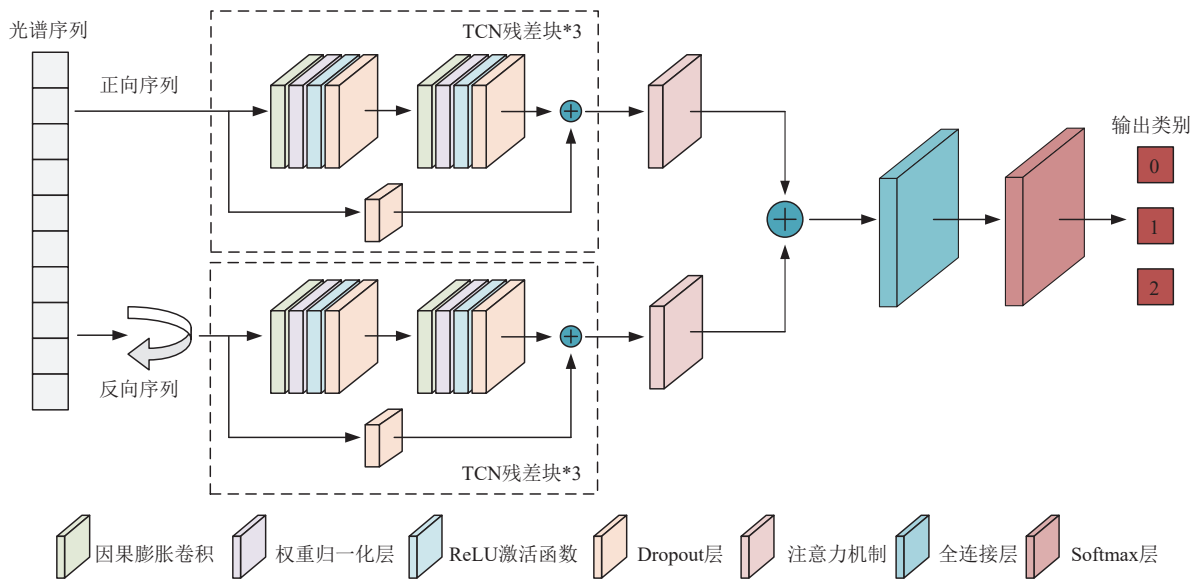


图 3 BiTCN-SA 网络结构
Fig. 3 BiTCN-SA network structure

膨胀卷积通过在卷积核间插入空洞扩大感受野,使网络在较少层数下捕捉远距离依赖关系,相比普通卷积,它能在不增加计算量的情况下提升特征提取能力,显著降低网络复杂度和计算量,如图 4 所示。引入膨胀卷积后,TCN 感受野更灵活,能够更全面学习时序信息特征。在处理一维数据 $[X_0, X_1, \dots, X_t, X_{t+1}]$ 时,隐藏层在第 t 时刻的输出值 $h(t)$ 如式(3)所示。

$$h(t) = \sum_{i=0}^{S-1} f(i) \cdot X_{t-d \cdot i} \quad (3)$$

式中: $h(t)$ 为第 t 时刻膨胀卷积的隐藏层输出, $f(i)$ 为膨胀卷积核中第 i 个元素, S 为卷积核大小, $X_{t-d \cdot i}$ 为间隔采样后对应的序列元素, d 为膨胀系数。

TCN 残差块以残差连接为核心,由膨胀卷积、权重归一化层、ReLU 激活函数、Dropout 正则化层、跳跃连接和 1×1 卷积构成,如图 5 所示。在




图 4 因果膨胀卷积
Fig. 4 Causal dilated convolution

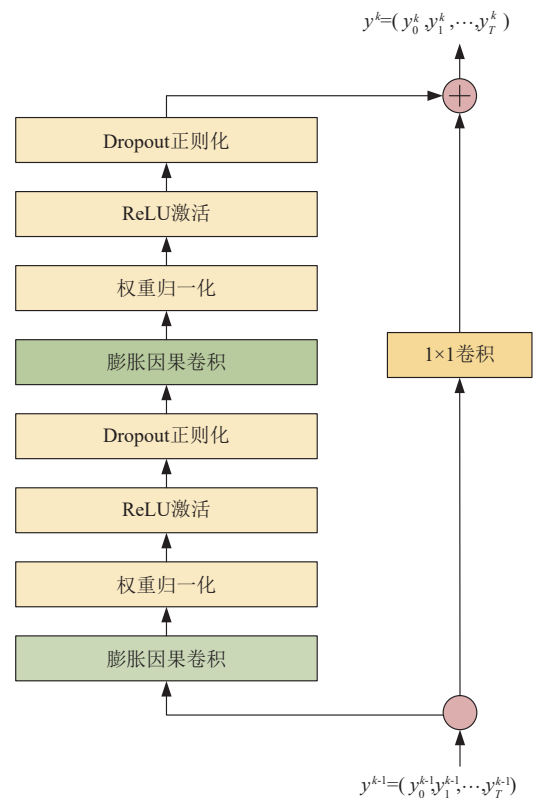


图 5 TCN 残差块
Fig. 5 TCN residual block

每个残差块内,输入经过因果膨胀卷积进行特征提取,随后通过 ReLU 激活函数引入非线性,再经过权重归一化提高训练效果,最后通过 Dropout 层进行正则化,以减少过拟合,其残差连接有效缓解梯度消失和网络退化问题,同时结合

非线性变换提升特征表达能力,从而增强深层网络的训练效果和梯度传播稳定性。TCN 模型是由残差块堆叠而成,输入数据经过 k 个残差块计算后输出如公式(4)和(5)所示。

$$\mathbf{y}^{(j,k)} = [\mathbf{y}_0^{(j,k)}, \dots, \mathbf{y}_T^{(j,k)}] \quad (4)$$

$$\mathbf{y}_t^{(j,k)} = \sum_{i=0}^{S-1} f(i) \mathbf{y}_{t-di}^{(j-1,k)} + \mathbf{y}_t^{(1,k)} \quad (5)$$

式中: $\mathbf{y}^{(j,k)}$ 为第 k 个残差块的第 j 层输出, j 为 1 或 2, k 为残差块号, $k \leq 3$ 。

对于单一 TCN 模型而言,在对光谱数据进行特征提取过程中,只进行前向卷积计算,忽略了反向的隐含信息,采用具有较强特征捕获能力的双向时域卷积网络^[24],实现双向特征提取,挖掘前后关联波段的深层特征。将正向第 3 层残差块的输出 \mathbf{y}^3 和反向第 3 层残差块的输出 $\mathbf{y}^{(3,r)}$ 进行加性融合,计算得到双向融合特征输出,计算如公式(6)所示。

$$\mathbf{z} = G(\mathbf{y}^3, \mathbf{y}^{(3,r)}) \quad (6)$$

式中: \mathbf{z} 为正反向支路特征融合的输出; G 为加性融合策略函数。

1.3.2 自注意力模块 自注意力机制(Self-Attention)模拟大脑从大量信息中选择性关注重要信息的过程^[25],通过计算相似度为特征分配权重,使模型在加权求和时更关注权重较大的特征,从而提取关键信息并降低数据维度。经过 TCN 残差块输出 \mathbf{y} 通过矩阵变换得到查询(Query-Q)、键(Key-K)和值(Value-V)矩阵,计算 \mathbf{Q} 和 \mathbf{K} 之间的相似度,得到每个 \mathbf{V} 的权重系数 \mathbf{A} ; 随后对 \mathbf{A} 进行 softmax 归一化,并与 \mathbf{V} 加权求和得到注意力值,计算如式(7)和(8)所示,其中 $\sqrt{d_k}$ 为 \mathbf{K} 的维度。

$$\mathbf{A} = \frac{\mathbf{Q} \cdot \mathbf{K}^T}{\sqrt{d_k}} \quad (7)$$

$$\text{Att}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{softmax} \left(\frac{\mathbf{Q} \cdot \mathbf{K}^T}{\sqrt{d_k}} \right) \mathbf{V} \quad (8)$$

1.3.3 特征融合模块 在正向和反向支路中分别融入自注意力模块,进一步动态建模波段间的全局依赖关系,关注重要性较高的波段。BiTCN-SA 模型在光谱序列两个方向上实现局部卷积特征与全局注意力权重的结合,使模型既能提取细节特征,又能关注全局波段重要性,提升模型鲁棒性。

经过正向和反向注意力机制的特征提取,正向第 3 层残差块的输出 \mathbf{y}^3 和反向第 3 层残差块的输出 $\mathbf{y}^{(3,r)}$ 通过自注意力机制特征提取,可分别计算得到 Att^3 和 $\text{Att}^{(3,r)}$ 。最后,采用加性策略将两者融合,并通过一次全连接操作后,最终输出至 Softmax 分类层。具体处理过程如下所示:

$$\mathbf{z} = G(\text{Att}^3, \text{Att}^{(3,r)}) \quad (9)$$

$$\mathbf{S}_i = \frac{\exp(\omega_c^T \mathbf{z})}{\sum_{c=1}^N \exp(\omega_c^T \mathbf{z})} \quad (10)$$

式中: \mathbf{z} 为正反向支路特征融合的输出; G 为加性融合策略函数; Att^3 为正向第 3 层注意力机制的输出; $\text{Att}^{(3,r)}$ 为反向第 3 层注意力机制的输出; \mathbf{S}_i 为经过 Softmax 分类层的输出; $\omega = \{\omega_1^T, \dots, \omega_N^T\}^T$ 为权重参数, ω_c 为第 c 类样本的权重参数, $c \in \{1, 2, \dots, N\}$ 为所属类别, N 为总类别数。

1.3.4 对比实验设计 为验证 BiTCN-SA 的优越性,本文采用机器学习、深度学习方法与其进行对比。其中,在机器学习模型对光谱数据进行建模前,由于原始光谱存在噪声干扰、共线性和冗余信息问题,通常需要提前进行预处理和波长选择。本文采用 SG 卷积平滑算法(Savitsky-Golay, SG)、多元散射校正(Multiplicative Scatter Correction, MSC)和标准正态变量变换(Standard Normal Variate, SNV)等 3 种预处理方法和 SPA 和 CARS 等 2 种波长选择方法。最后,将预处理方法、特征波长选择算法与 SVM、RF 等传统机器学习模型组合建模,进行对比分析。

TCN 的因果膨胀扩张卷积是对 CNN(Convolutional Neural Networks, CNN)传统卷积核的改进, CNN 的传统卷积核提取能够提取光谱波段的局部特征^[26]。LSTM(Long Short-Term Memory, LSTM)处理时序数据同样具有优秀的性能^[27],其处理光谱序列的优点在于其门控机制能动态捕捉波段间的复杂依赖关系。因此,本文采用 CNN、LSTM 等深度学习方法与所提模型进行对比,在处理光谱序列过程中,对比其特征提取能力以验证 BiTCN-SA 的优越性。

1.4 模型评价

将扩充的 3 600 个原始光谱数据通过分层抽样的方式按 3:1 划分为训练集和测试集,训练集中各等级样本数量为 900 个,共 2 700 个;测试集

中各等级样本数量为300个,共900个,样本数量均匀覆盖各等级。模型性能通过准确率(Accuracy)、精确率(Precision)、召回率(Recall)、F1得分(F1 Score)等4个评价指标进行评估,其计算公式如下:

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \quad (11)$$

$$\text{Precision} = \frac{TP}{TP + FP} \quad (12)$$

$$\text{Recall} = \frac{TP}{TP + FN} \quad (13)$$

$$\text{F1 Score} = \frac{2 \times \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} = \frac{2TP}{2TP + FP + FN} \quad (14)$$

式中:TP为预测为正类且实际为正类的样本数。TN预测为负类且实际为负类的样本数;FP预测为正类但实际为负类的样本数;FN:预测为负类但实际为正类的样本数。准确率表示正确预测的样本数占总样本数的比例;精确率为预测为正类的样本中,实际为正类的比例;召回率为实际为正类的样本中,被正确预测为正类的比例;F1得分分为精确率和召回率的调和平均数。

2 结果与分析

2.1 光谱数据分析

为对比各等级的光谱曲线变化,对每个等级的光谱反射率取平均值,如图6所示。在不同时期,各等级光谱曲线在550 nm和680 nm处都存

在明显波峰和波谷。560~710 nm处,光谱反射率随着患病时间升高,这是由于叶肉组织内叶绿素被破坏所导致。在760~950 nm近红外波段,这是由于水分的丢失所导致患病叶片反射率降低。




图6 各等级的马铃薯晚疫病叶片平均光谱
Fig. 6 Average spectra of potato late blight leaves by class

2.2 机器学习模型结果分析

本文将SNV、MSC、SG三种预处理方法与原光谱RAW分别建立SVM模型,对比模型效果优选出最佳预处理方法作为传统模型后续处理和建模的数据,模型结果如表1所示。由表1可得,SNV和MSC处理后的模型准确率相比原光谱有所降低,这是因为这两种方法消除噪声的同时也减少了有效光谱信息。经过SG处理的模型性能最好,将其作为特征波长选择的输入,特征波长分布如图7所示。

表1 基于三种预处理方法和原光谱的SVM模型结果(%)

Table 1 SVM model results based on three preprocessing methods and the original spectra

模型 Model	准确率 Accuracy	精确率 Precision	召回率 Recall	F1得分 F1-score
RAW	87.57	87.63	87.57	87.60
SNV	85.31	86.52	85.31	85.08
MSC	86.21	87.33	86.21	86.77
SG	88.58	88.02	88.58	88.30

经过SPA、CARS特征选择后,波长数量仅占原来的6.9%、9.9%。最后建立基于特征波长和全波长(Full)的分类器模型,结果如表2所示,经过SPA选择特征波长后,RF和SVM模型准确率都有不同程度降低,可能原因是SPA提取特征信息不充分所导致;经过CARS选择特征波长后,RF和SVM模型准确率都有不同程度升高,

其中CARS-SVM模型性能最好,准确率达到92.33%。

2.3 模型训练及测试结果分析

实验环境配置:操作系统:Windows 11;CPU: Intel(R) Core (TM) i5-9300H CPU 2.40 GHz;内存: 8G;显卡:NVIDIA GeForce GTX 1060。BiTCN-

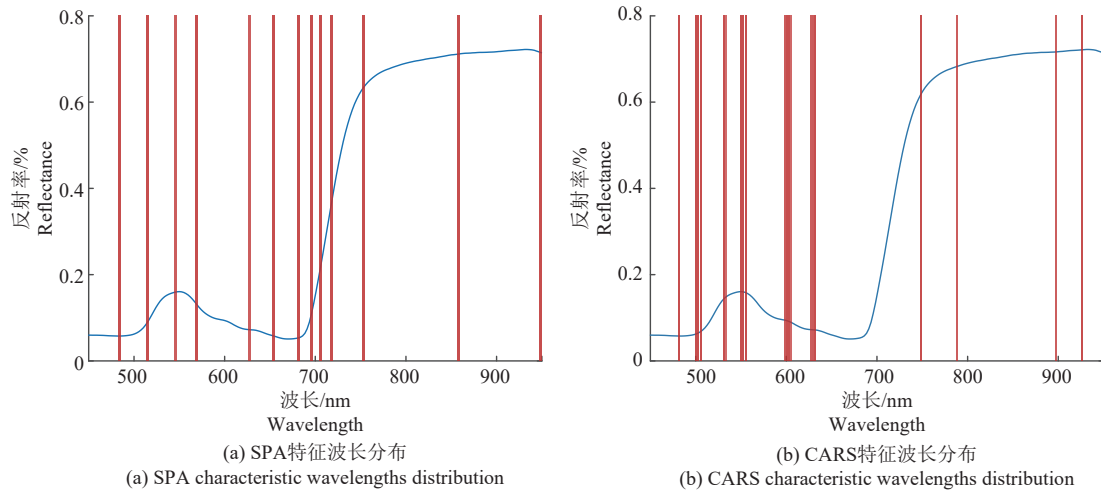


图7 特征波长

Fig. 7 Characteristic wavelengths

表2 SG处理后基于不同特征波长选择算法的SVM、RF模型结果

Table 2 SVM and RF model results based on different feature wavelength selection algorithms after SG processing

模型 Model	波长数 Number of wavelengths	准确率/% Accuracy	精确率/% Precision	召回率/% Recall	F1得分/% F1-score
Full-RF	203	84.53	86.56	84.53	85.53
Full-SVM	203	88.58	88.02	88.58	88.30
SPA-RF	14	80.59	81.09	80.59	80.83
SPA-SVM	14	87.78	88.50	87.78	87.90
CARS-RF	20	88.00	88.48	88.00	88.25
CARS-SVM	20	92.33	92.30	92.33	92.31

SA模型的参数设置:批量大小:128;优化器:Adam;学习率:0.001;卷积核尺寸:3x1;卷积核数量:32*32*32;TCN残差块数:3+3;膨胀系数:1,2,4;Dropout率:0.05。

将TCN、BiTCN和BiTCN-SA模型进行对

比,以验证所提模型的优越性,模型训练结果如图8所示。图8为3个模型在600次迭代中准确率和损失值的曲线变化,由图可得3个模型在500次迭代后准确率和损失值逐渐趋于稳定,第500次到600次迭代的损失值变化<10%,经过

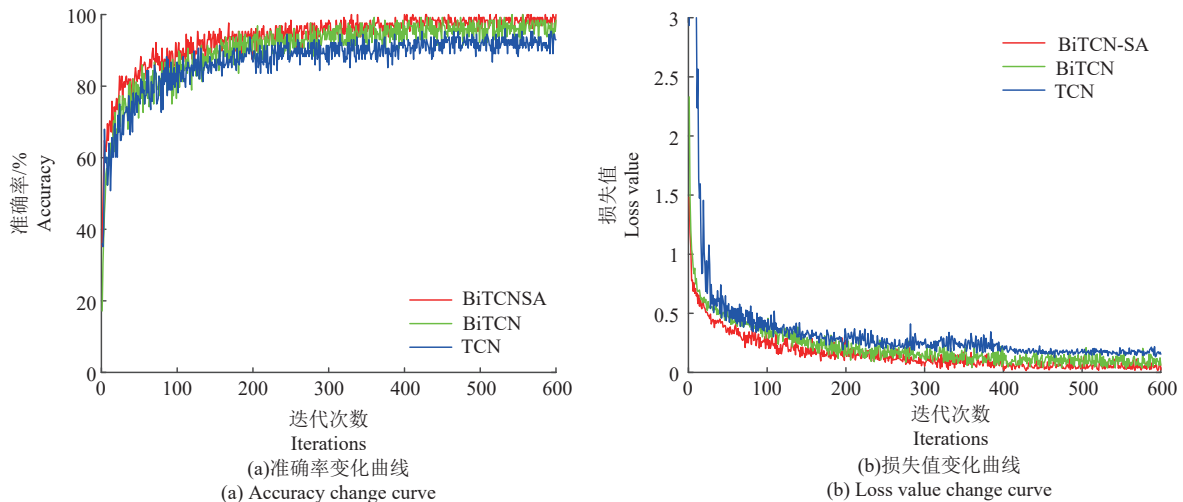


图8 训练阶段的损失和准确率曲线对比

Fig. 8 Comparison of loss and accuracy curves for the training phase

600 次迭代 3 个模型训练损失值曲线收敛, 前 300 次迭代 BiTCN 比 TCN 的收敛速度更快, 准确率更高, 损失值更小, 这是由于其双向结构为输出层同时提供双向的光谱序列信息, 充分利用前后波段的关联性, 而 BiTCN-SA 相较于两者收敛速度更快, 准确率更高, 损失值更小, 这是由于其引入的自注意力机制能够为重要波段分配更高的权重, 从而更有效地提取关键特征波段, 强化了双向结构的特征提取能力, 显著提高了收敛速

度和准确率。

为了探究不同深度学习模型在早期识别上的差异, 本文另外加入 CNN、LSTM 等 2 种分类器进行对比, 各模型测试集的预测结果如表 3 所示, 5 种分类模型准确率都达到了 90% 以上, 表明这 5 种深度学习模型同样适用光谱序列的处理, 其中 BiTCN-SA 模型性能最好, 准确率为 98.00%, 精确率为 98.00%, 召回率为 98.00%, F1 得分为 97.99%, 相比于其他模型有显著提高。

表 3 TCN、BiTCN 和 BiTCN-SA 模型结果 (%)
Table 3 TCN, BiTCN and BiTCN-SA modeling results

模型 Model	准确率 Accuracy	精确率 Precision	召回率 Recall	F1 得分 F1-score
CNN	91.11	91.37	91.11	91.12
LSTM	92.48	92.47	92.49	92.46
TCN	92.67	92.71	92.67	92.67
BiTCN	95.22	95.24	95.22	95.23
BiTCN-SA	98.00	98.00	98.00	97.99

2.4 不同模型结果对比分析

为了进一步分析各模型在不同等级上的分类效果, 绘制 6 种模型 (SG-CARS-SVM、CNN、LSTM、TCN、BiTCN、BiTCN-SA) 的混淆矩阵, 结果如图 9 所示。由图 9 可知, SG-CARS-SVM

对等级 0 的识别度较高, 在等级 1 和等级 2 误判较多, 这是因为部分叶片样本受到致病疫霉的侵染但未出现肉眼可见病斑, 但其内部感染组织反映出的光谱信息与病症初期样本相似, 模型倾向于学习等级 0 的光谱特征。LSTM、CNN、TCN

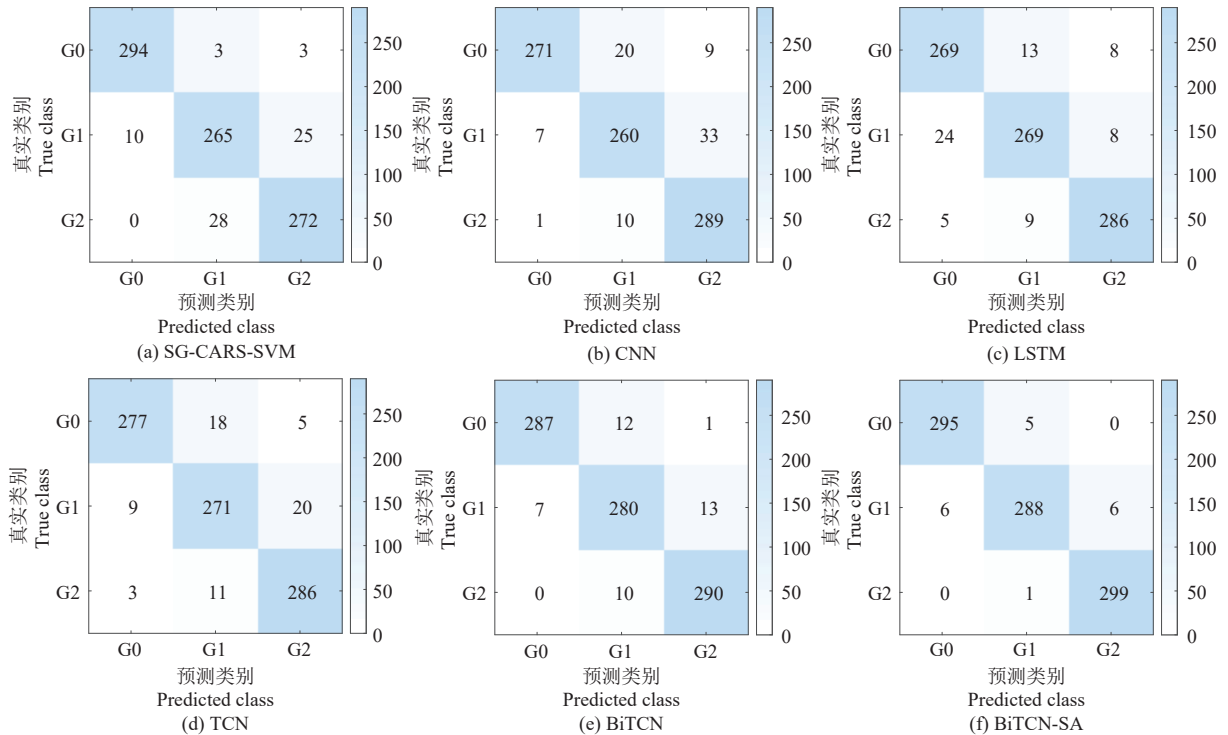


图 9 各模型识别结果的混淆矩阵
Fig. 9 Confusion matrices for the identification results of each model

对等级 2 的识别度较高,在等级 0 和等级 1 误判较多,在区分无症状期和健康样本时存在一定的困难,这是因为部分无症状叶片相较于健康叶片的光谱仅发生了微小变化,故而容易造成误判,模型更倾向于学习等级 2 的光谱特征。其可能原因是 LSTM 过度关注长序列依赖关系,CNN、TCN 主要依赖局部特征提取,对全局细微的光谱变化敏感度较低,因此在等级 0 和等级 1 的识别效果较差。

本文所提出的 BiTCN 在 3 种等级的辨别率上比较均衡,这说明某些波段在反向分析时可能更具判别性,该模型能更好实现马铃薯晚疫病的早期预警识别。BiTCN-SA 模型各等级准确率最高,无症状期病叶的识别率达到 96%。SG-CARS-SVM 无法充分利用深层光谱特征,提取部分波段特征损失有效信息,CNN 在光谱序列中由于其受限于固定感受野可能导致“信息视野狭窄”,LSTM 需逐波段递归计算导致训练效率低下,且难以有效建模长距离跨波段的依赖关系。BiTCN-SA 其双向结构结合 TCN 因果膨胀卷积和自注意力的双重特征提取机制,在早期光谱变化差异不明显的叶片样本中,相比于 CNN、LSTM 等其他深度学习模型,BiTCN-SA 具备更强大的特征提取能力,能够实现晚疫病早期的高精度识别。

3 结论

为实现马铃薯晚疫病早期的高精度识别,针对高光谱数据因光谱维度高导致特征提取不充分、预测精度不足等问题,本文提出了 BiTCN-SA 用于马铃薯晚疫病早期识别,该模型的双向卷积结构捕捉局部多尺度特征和双向波段依赖,充分利用前后波段间关联性,融入的自注意力机制在全局上为关键波段动态分配更高的权重,提高重要波段对识别模型的贡献率,形成局部时序卷积结合全局注意力的双重特征提取机制。对比多种机器学习、深度学习模型,结果表明:BiTCN-SA 模型与单一 TCN 和 BiTCN 相比,模型精度和收敛速度显著提升;与 SG-CARS-SVM 等传统机器学习模型相比,总体准确率比 SG-CARS-SVM 高出 5.67%,且简化了建模过程,提高了建模效率;相较于 CNN、LSTM 等其他深度学习方法,BiTCN-SA 对 3 个等级都能实现高精

度识别,无症状期识别率达到 96%,表明在叶片病变早期,光谱变化差异不显著的情况下,该模型具备更强大的特征提取能力。该深度学习模型为马铃薯晚疫病的早期预警提供了有力支持,且为其他农作物病害识别提供新思路。

参考文献

- [1] 侯冰茹,刘鹏辉,张洋,等.基于马铃薯叶片光纤光谱信息的晚疫病患病程度预测[J].光谱学与光谱分析,2022,42(05):1426-1432.
- [2] 罗攀攀,武强,朱玉涵,等.基于 CARAH 模型的重庆春马铃薯晚疫病侵染特征模拟分析[J].植物保护,2024,50(04):80-90.
- [3] 沈梦姣,鲍浩,张艳.基于光谱-纹理特征的辣椒早疫病潜育期高光谱图像检测识别[J].生物化学与生物物理进展,2025,52(01):233-243.
- [4] Zhang N, Yang G J, Pan Y C, et al. A review of advanced technologies and development for hyperspectral-based plant disease detection in the past three decades[J]. Remote Sensing, 2020, 12(19):34.
- [5] Li X, Fu X L, Li H H. A CARS-SPA-GA feature wavelength selection method based on hyperspectral imaging with potato leaf disease classification[J]. Sensors, 2024, 24(20):18.
- [6] Tang Y, Yang J P, Zhuang J J, et al. Early detection of citrus anthracnose caused by *Colletotrichum gloeosporioides* using hyperspectral imaging[J]. Comput Electron Agric, 2023, 214:11.
- [7] Zhou Y X, Chen J Z, Ma J F, et al. Early warning and diagnostic visualization of *Sclerotinia* infected tomato based on hyperspectral imaging[J]. Scientific Reports, 2022, 12(1):13.
- [8] 潘健,祁雁楠,陈鲁威,等.基于可见/近红外高光谱成像技术的梨树叶部病害识别研究[J].中国农机化学报,2024,45(08):162-169.
- [9] Khan A, Vibhute A D, Mali S, et al. A systematic review on hyperspectral imaging technology with a machine and deep learning methodology for agricultural applications[J]. Ecological Informatics, 2022, 69:12.
- [10] Wang C Y, Liu B H, Liu L P, et al. A review of deep learning used in the hyperspectral image analysis for agriculture[J]. Artificial Intelligence Review, 2021, 54(7):5205-5253.
- [11] Chun S W, Song D J, Lee K H, et al. Deep learning algorithm development for early detection of *Botrytis cinerea* infected strawberry fruit using hyperspectral fluorescence imaging[J]. Postharvest Biology and

- Technology,2024,214:15.
- [12] 魏雷,徐迎波,曹海兵,等.基于AE-BiRNN的片烟含水率高光谱检测[J].烟草科技,2024,57(02):70-78.
- [13] 邓昀,牛照文,冯琦尧,等.改进时间卷积网络的红壤有机质高光谱预测模型[J].光谱学与光谱分析,2023,43(09):2942-2951.
- [14] 吴叶兰,管慧宁,廉小亲,等.基于高光谱成像和Att-BiGRU-RNN的柑橘病叶分类[J].农业机械学报,2023,54(01):216-223.
- [15] 徐胜勇,刘政义,黄远,等.基于Self-Attention-BiLSTM网络的西瓜种苗叶片氮磷钾含量高光谱检测方法[J].农业机械学报,2024,55(08):243-252.
- [16] 蒋雪松,计恺豪,姜洪喆,等.深度学习在林果品无损检测中的研究进展[J].农业工程学报,2024,40(17):1-16.
- [17] Hou B R, Hu Y H, Zhang P, et al. Potato late blight severity and epidemic period prediction based on Vis/NIR spectroscopy[J]. Agriculture-Basel, 2022, 12(7):17.
- [18] Li Q Y, Hui Y H. Kinetic models of peroxidase activity in potato leaves infected with late blight based on hyperspectral data[J]. International Journal of Agricultural and Biological Engineering, 2019, 12(2):160-165.
- [19] 郭兆华,文师召,李思凡,等.基于近红外光谱结合数据增强CNN算法的白芷产地溯源方法[J].中国药学杂志,2024,59(21):2022-2029.
- [20] Tang Z J, Zhang J Y, Hu M L, et al. Improving streamflow forecasting in semi-arid basins by combining data segmentation and attention-based deep learning[J]. Journal of Hydrology, 2024, 643:14.
- [21] 温廷新,郭晓赛.基于特征组合的ECA-TCN光伏发电功率预测模型[J].太阳能学报,2024,45(12):94-100.
- [22] 赵玉,陈丽霞,梁梦姣.基于LSTM-TCN模型的降雨型滑坡时间概率预测及气象预警建模[J].地质科技通报,2024,43(02):201-214.
- [23] 崔笑宁,苏丹华,尚维.基于互联网新闻和时间卷积长短时记忆神经网络的股票指数预测研究[J].管理评论,2024,36(07):113-127.
- [24] Zhang D D, Chen B A, Zhu H Y, et al. Short-term wind power prediction based on two-layer decomposition and BiTCN-BiLSTM-attention model[J]. Energy, 2023, 285:19.
- [25] Wang W C, Ye F R, Wang Y Y, et al. A singular spectrum analysis-enhanced BiTCN-selfattention model for runoff prediction[J]. Earth Science Informatics, 2025, 18(1):29.
- [26] 刘涛,刘望,杨奉源,等.基于无人机高光谱影像和机器学习算法的花生生物量估算方法研究[J].中国农业大学学报,2025,30(03):206-217.
- [27] 汤森林,张霞,戚文超,等.基于长短时记忆神经网络的葡萄叶面积指数高光谱反演[J].遥感信息,2022,37(05):38-44.