高光谱和卷积神经网络的大白菜农残检测

姜荣昌1,2,顾鸣声2,赵庆贺1,李欣然1,沈景新1,3,苏中滨1*

- 1. 东北农业大学电气与信息学院,黑龙江 哈尔滨 150030
- 2. 哈尔滨市大数据中心, 黑龙江 哈尔滨 150030
- 3. 山东省农业机械科学研究院, 山东 济南 250100

摘 要 针对大白菜农药残留传统化学检测手段存在前期处理过程繁琐、检测周期长等不足,提出了一种快速无损识别大白菜农药残留种类的方法。以1组无农药残留和4组含有均匀喷洒农药(毒死蜱、乐果、灭多威和氯氰菊酯)的大白菜样本为研究对象(药液浓度配比分别为0.10,1.00,0.20和2.00 mg·kg⁻¹),经12小时自然吸收后,利用高光谱成像系统获取400~1000 nm高光谱图像,并选取ROI感兴趣区域后经多元散射校正(MSC)预处理;分别采用竞争性自适应重加权算法(CARS)、主成分分析算法(PCA)和离散小波变换(DWT)降维(分别基于db1,sym2,coif1,bior2.2和rbio1.5小波基函数);最后,将降维后的高光谱数据分别输入卷积神经网络(CNN)、多层感知机(MLP)、K最邻近算法(KNN)和支持向量机(SVM)建立模型并比较。结果显示,CNN,MLP,KNN和SVM算法均在降维算法DWT(小波基函数及变换层数分别为coif1-2,coif1-4,bior2.2-2和sym2-2)取得最优总体精度分别为91.20%,83.20%,66.40%和90.40%,Kappa系数分别为0.89,0.79,0.58和0.88,预测集用时分别为86.01,63.23,20.02和14.03ms,总体精度和Kappa指标均优于基于CARS和PCA降维算法建模结果。可见,高光谱与离散小波变换和卷积神经网络相融合显著提高分类识别精度,改善"休斯"现象,为实现无损和快速检测识别大白菜农残提供一个新的方法。

关键词 高光谱; 大白菜; 农残检测; 离散小波变换; 卷积神经网络

中图分类号: O433.4 文献标识码: A DOI: 10.3964/j. issn. 1000-0593(2022)05-1385-08

引言

大白菜营养丰富价格低廉,经过加工腌制后可做成泡菜、酸菜等,是老百姓餐桌上不可或缺的美味佳肴。在大白菜种植过程中不可避免的使用农药来防治病虫害。一些农户缺乏农药用药常识,片面追求高产,使得农药的不规范使用、滥用问题日益严重,造成大白菜叶片中残留过量农药;实验证明成年人长期食用含有农药残留超限的蔬菜后,会出现腹泻、肠道菌群失调或慢性中毒等不同反应;儿童会出现非正常性生理早熟、智力发育迟缓,重度可导致身体畸形和基因突变。因此,如何无损、快速、准确的进行大白菜农残检测具有十分重要的意义。

现阶段农药残留化学检测常用方法有理化分析法和免疫 分析法,虽然这两种方法具有高灵敏度和精度,但是,理化 分析法和免疫分析法检测前都需要较复杂的预处理工序,费 时、费力、有破坏性,而且易出现假阴性或假阳性^[1]等现象。随着光谱技术不断进步,基于光谱技术的农药残留检测应用逐渐增多,常见的光谱技术有基于拉曼和红外光谱技术^[2-3],由于检测机理的限制,拉曼和红外光谱易受环境干扰,影响测量精度和灵敏度。

近几年高光譜技术在农作物农药残留检测方面应用逐渐增多,高光譜技术与拉曼和红外等光谱技术相比具有图谱合一的优点,不仅提供光谱空间分布信息,而且高度连续且密集光谱信号可对被测物体化学组成精确定量分析;Sun等^[4]利用高光谱技术获取生菜叶片高光谱数据并建模,基于随机森林-递归特征消除-连续投影算法-最小二乘支持向量回归(RF-RFE-SPA-LSSVR)模型能够识别混合农药残留,模型预测准确率为93.86%。吉海彦等^[5]利用高光谱成像仪采集菠菜叶片900~1700 nm光谱数据,采用卡方检验特征选择算法筛选出8个特征波长后,再利用支持向量机建立识别模型,模型预测准确率为99.30%,能够准确识别菠菜叶片农

收稿日期: 2021-08-03, 修订日期: 2021-10-31

基金项目: 黑龙江省"百千万"工程科技重大专项(2019ZX14A0401)资助

作者简介:姜荣昌,1982年生,哈尔滨市大数据中心高级工程师,东北农业大学电气与信息学院博士研究生

药残留。

针对现阶段农药残留检测方法的不足和大白菜农残无损、快速检测空白,利用高光谱技术的优点,提出了一种基于高光谱离散小波变换和卷积神经网络(CNN)的大白菜农药残留检测识别算法,应用于大白菜样本高光谱数据集,验证所提算法的可靠性和准确度,为后期建立基于便携式农药残留检测设备打下基础。

1 实验部分

1.1 样本制备

实验所用的大白菜样本均采购于哈尔滨市某大型商超。 实验农药为 40%毒死蜱(市售,河北八源生物制品有限公司)、58.00 mg·L⁻¹ 乐果(网购,中国计量科学研究院)、90%灭多威(市售,山东华阳农药化工集团有限公司)和4.5%氯氰菊酯(市售,安徽尚禾沃达生物科技有限公司)。按照《中华人民共和国食品安全国家标准 GB2763—2019》中大白菜最大农药残留限量要求,分别将毒死蜱、乐果、灭多威和氯氰菊酯分别配置 0.10,1.00,0.20 和 2.00 mg·kg⁻¹的药溶液分别装入 4 个喷壶内,喷射距离 8~10 cm,每种药溶喷洒 10 个样本,共计 40 个样本,均匀喷后平放置于室温(温度 20 ℃,湿度 65%RH)自然吸收 12 h后采集高光谱影像数据(共 50 个样本,其中 10 个为无农药残留样本)。

1.2 高光谱成像系统

高光谱采集设备使用美国 Headwall Photonics 公司生产的高光谱成像系统,由面阵 CCD、光栅光谱仪、高光谱成像镜头、均匀光源、一维电动台、USB1394 图像采集卡、高性能图形工作站及相关采控软件构成。实验所用高光谱相机分辨率为 1 000×164 Pix,位深度为 24 bit,线性阵列扫描成像方式;光栅光谱仪的光谱范围为 400~1 000 nm,共有 800 个波段,光源由 2 个 200 W 溴钨灯构成,位于电动台两侧,人射角呈 45°;采控软件通过 RS232 串口控制电动台移动速度及方向,如图 1 所示。

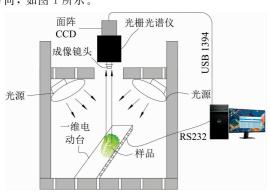


图 1 高光谱成像系统结构示意图

Fig. 1 Schematic diagram of hyperspectral imaging system

1.3 高光谱图像数据标定与采集

高光谱图像采集过程中会受到两方面干扰,一方面是由于大白菜样本形状各异、表面高低不平等原因会产生漫反

射;另一方面是由于电网中暗电流和谐波的存在,导致相机工作状态不稳定,产生较大的图像噪声,影响光谱采集效果。因此,在采集前必须对高光谱相机进行参数设置和黑白校正,经多次调试和效果比对,最终曝光时间设置为 0.03 s,电动台的移动速度参数设置为 3.0 mm · s⁻¹,镜头垂直向下距电动台 450 mm。

后续所使用的数据分析处理软件包括: ENVI 5.2(ITT Visual Information Solutions, Boulder, Co., USA), Origin-Pro 8 (OriginLab Co., Ma, USA), The Unscrambler X 10.4, Python 3.6, TensorFlow 2.0 等软件。

1.4 样本感兴趣区域选取

为方便数据采集将大白菜样本裁剪为 16 cm×8 cm 长方条,使用 ENVI 软件在每个大白菜样本上避开主茎干选取 40 个感兴趣区域(region of interest, ROI),选取位置如图 2 所示。每个 ROI 选择的范围是 30×30 Pix,计算出这 900 个像素点平均光谱反射值作为一条光谱记录,共计 2 000 条(5×400)光谱记录。

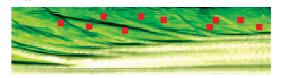


图 2 大白菜样本 ROI 选取示意图

Fig. 2 Schematic representation of selection of ROI on Chinese cabbage sample

1.5 光谱预处理与噪声裁剪

在高光谱图像采集过程中,会受到来自样本自身因素干扰(如样本平整度、色差和水分含量等)和环境因素干扰等,为了减少上述干扰的影响,需要对高光谱图像进行光谱预处理以消除干扰影响。使用 Unscrambler 软件对高光谱数据进行多元散射校正(multiple scattering correction, MSC)预处理;5组样本各随机选取200条光谱在预处理前与后的谱形如图3所示。图3(a)为未经光谱预处理的原始样本曲线,图3(b)为经MSC预处理后样本曲线。

如图 3(b)所示,靠近 400 和 1 000 nm 边缘波段光谱反射曲线波动较剧烈,说明此处受到干扰较大,数据严重失真,影响后期建模分类效果;因此,需要进行噪声裁剪,为每个样本掐头去尾剔除噪声较大 400~414 和 912~1 000 nm 的边缘波段,保留 415~911 nm(对应原 800 波段中的 20~749,共计 729 波段)用于建模分析。

1.6 离散小波变换降维算法

小波变换(wavelet transform, WT)是一种信号变换分析方法,提供一种随频率改变的"时间-频率"窗口,通过小波基函数的伸缩平移运算实现信号(函数)多尺度、多分辨细化,可同时提取细节分量(高频部分)和近似分量(低频部分),连续小波变换表达式为

$$WT(j,k) = \langle f(\lambda), \Psi_{j,k}(\lambda) \rangle = \frac{1}{\sqrt{|j|}} \int_{-\infty}^{+\infty} f(\lambda) \Psi\left(\frac{\lambda - k}{j}\right) d\lambda$$

(1)

式(1)中,j为缩放因子,k为平移因子,j和k均为连续变量,

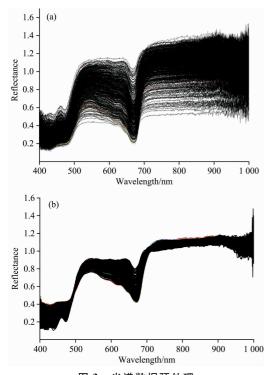


图 3 光谱数据预处理

(a): 原始光谱; (b): 经 MSC 处理

Fig. 3 Spectral data preprocessing by MSC

(a): Without preprocessing; (b): With MSC preprocessing

量, $\Psi(\lambda)$ 为小波基函数。

离散小波变换^[6] (discrete wavelet transform, DWT)是小波变换的一种,可实现在离散尺度上进行信号分解,通过高低通滤波器来实现高低频信号分解,离散变换公式为

$$DWT(a,b) = \langle f(\lambda), \phi_{a,b}(\lambda) \rangle$$
 (2)

式(2)中,a和b分别为第a层分解和第b个小波系数, $\phi_{a,b}$ (λ)为离散小波基函数。

将高光谱数据中的波长-反射率与信号的时间-频率相对应,利用离散小波变换多尺度分解特性实现降维,既每层变

换均略去细节分量(高频部分),将分解后的近似分量(低频部分)作为建模数据,以此类推,每层变换均在上层变换的近似分量基础上进行再变换,每层变换数据维度减半,达到数据降维目的。

1.7 分类识别模型的建立

1.7.1 多层感知机

所使用的多层感知机(multilayer percetron, MLP)^[7]具有4个全连接层和1个输出层,网络结构如表1所示;设置学习率 learning_rate(LR)为0.001,迭代次数 epochs为500,批量大小为batch_size(BS)为64,测试集验证频率 validation_freq为1,优化器使用Adam算法。

表 1 多层感知机网络结构 Table 1 MLP network structure

层	神经元个数	激活函数
全连接层 FC1	512	relu
全连接层 FC2	256	relu
全连接层 FC3	256	relu
全连接层 FC4	128	relu
输出层	5	softmax

注: relu 是线性修正单元激活函数 Note: relu is rectified linear unit

1.7.2 卷积神经网络

卷积神经网络^[8] (convolutional neural networks, CNN) 是一种在多层感知机基础上建立的深度学习网络,通过增加若干个卷积层(convolution layer)来增强网络的特征抓取能力。虽然经典模型如 AlexNet(8 层)、VGGNet(11~19 层)、GoogLeNet(Inception V1 22 层)、ResNet(18~152 层)分类效果较好,但模型层数较多、参数量巨大,对硬件性能要求较高。本工作重新设计卷积神经网络结构如图 4 所示;高光谱大白菜样本图像经 ROI 提取、预处理和噪声裁剪后数据为2 $000\times1\times1\times729$,为了便于二维卷积运算,将光谱数据变形为 2 $000\times27\times27\times1$ (all_batch \times width \times height \times channels),卷积神经网络结构参数设置如表 2 所示。

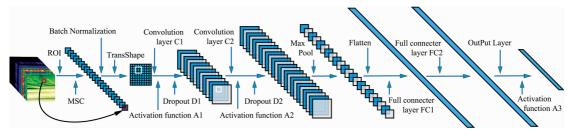


图 4 卷积神经网络结构

Fig. 4 CNN structure

卷积神经超参数的选取直接影响到识别模型分类精度,为了确定关键超参数 Learning_rate, Batch_size 和 Epochs, 高光谱数据经多次、多参数训练, 如图 5 所示; 图 5(a)为 Batch_size=50, Epochs=1 000 时, 4 种不同 Learning_rate 下的模型训练损失值, 从中可以看出当 Learning_rate 为 0.005 和 0.01 时均出现 Training loss value(TLA)为不变值

1. 6,说明此时 Learning_rate 过大,导致模型无法收敛;当 Learning_rate 为 0.001 时模型收敛速度较快。图 5(b)为 Learning_rate=0.001, Epochs=1 000 时,6 种不同 Batch_size下的模型训练损失值,中可以看出当 Batch_size 为 70,90,110 和 130 时 Training loss value 下降缓慢且振荡剧烈,说明此时模型不稳定,泛化能力较弱;仅当 Batch_size 为 50

表 2 卷积神经网络结构参数设置

Table 2 Parameter settings of the CNN structure

	_			
	离散小波变换层数			
层	1~4	5~6		
卷积炽 C1	$3\times3\times16$	$3\times3\times16$		
激活层 A1	relu	relu		
舍弃层 D1	0.3	0.3		
卷积层 C2	$5 \times 5 \times 32$	$3\times3\times32$		
正则层 L21	0.001	0.001		
激活层 A2	relu	relu		
舍弃层 D2	0.5	0.5		
池化层 MaxPooling	$2\times2\times2$	$2\times2\times2$		
全连接层 FC1	256	256		
全连接层 FC2	256	256		
正则层 L22	0.001]]0.001			
输出层	5	5		
激活层 A3	softmax	softmax		

注:卷积层 $n \times n \times m$ 表示为m 个卷积核大小为 $n \times n$ 的过滤器;池化层 $n \times n \times m$ 表示池化核大小为 $n \times n$,步长为m

Note: Convolution layer $n \times n \times m$ represents m filters with the convolution kernel size of $n \times n$; Pooling layer $n \times n \times m$ represents the pooling kernel size of $n \times n$ and the step size of m

时 Training loss value 下降迅速且起伏较小。图 5(c)为 Learning_rate=0.001, Batch_size=50时,6种不同 Epochs 下的模型训练损失值,从中可以看到随着 Epochs 不断增加,总体精度(overall accuracy,OA)呈明显上升趋势,当 Epochs

为 1 000 时, OA 到达顶峰。综合考量,最终确定超参数 Learning_rate 为 0.001, Batch_size 为 50, Epochs 为 1000, 优化器采用 Adam 算法。

为了更全面比较模型性能和精度,同时还采用支持向量机(support vector machine, SVM)和 K 最邻近(K-nearest neighbor, KNN)机器学习算法进行建模。

由于样本数量较少,容易发生模型过拟合,在建模过程中引入数据增强技术(data augmentation),在原有的高光谱数据基础上增加高斯噪声,将样本数据量扩充为原来的2倍;除此之外,还采用 Dropout 和 Regularization L2 技术提高模型泛化能力和鲁棒性。

2 结果与讨论

2.1 样品光谱曲线分析

为了从光谱曲线角度清楚地区分不同类型的样品之间的 光谱信息的差异,将每类样品的 400 条光谱曲线取平均值, 得到该平均光谱曲线如图 6 所示。

由图 6 可以看出,在 $400 \sim 700$ nm 波段内,出现 3 次较为明显反射波谷,分别出现在 410 nm 紫光、490 nm 青光和 667 nm 红光附近;在 $667 \sim 710$ nm 波段内反射率陡然上升,710 nm 波段后反射率逐渐平稳,符合绿色叶片光谱反射率规律。在 $530 \sim 667$ nm 波段内 5 条光谱反射曲线区分度较高,印证了叶片光谱反射率与农药胁迫存在相关联理论^[9],为实现通过光谱对大白菜农药残留进行识别提供了科学依据。

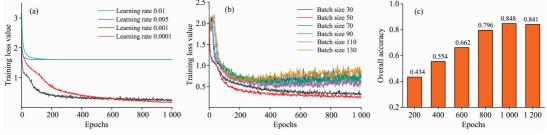


图 5 卷积神经网络超参数选择

(a): 基于 4 种 Learing rate 的模型训练损失值; (b): 基于 6 种 Batch size 的模型训练损失值; (c): 基于 6 种 Epochs 的模型总体精度

Fig. 5 CNN hyperparameter selection

(a): TLA for different LR; (b): TLA for different BS; (c): OA for different Epochs

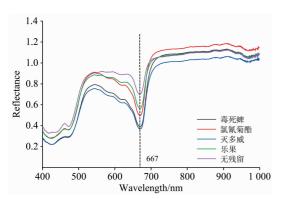


图 6 大白菜样本平均光谱曲线

Fig. 6 Average spectra of chinese cabbage samples

2.2 降维算法分析

2.2.1 离散小波变换降维

为了比较降维效果,以 db1 小波基为例,在平均光谱曲线上进行离散小波变换,每次变换后均只保留低频分量,舍弃高频噪声分量,1~6 层离散变换降维后得到的数据维度分别为 364,182,91,45,22 和 11。

降维后的光谱曲线如图 7 所示,可以看到随着变换层数的增加,曲线形状与原始曲线差异逐渐变大;图 7(a)为经过1 层离散小波变换后的低频分量曲线,与图 6 相比具有较高的相似性,能够较好的表征原曲线之间相对位置关系,但所用数据维度只占原数据的 1/2;随着离散小波变换层数的增加,数据维度以 2-m 递减(m 为小波变换层数),图 7 (f)为

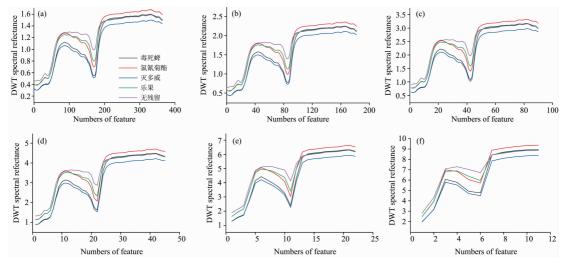


图 7 基于 db1 小波基函数离散小波变换后的低频部分曲线

(a)-(f)分别经1~6层离散小波变换

Fig. 7 Low frequency portions of wavelet transform based on db1 function

(a)—(f) corresponding to 1∼6 layers of DWT, respectively

经过 6 层离散小波变换后的曲线,虽然数据维度只有 11 维,仍能够看出在关键的节点处曲线相对位置关系。

2.2.2 PCA 和 CARS 降维

采用主成分分析(principal component analysis, PCA)算法对所有裁剪后的大白菜高光谱数据进行降维,前11,22,45,91,182和364主成分累计贡献率分别为99.11%,99.48%,99.76%,99.91%,99.98%和99.99%。

采用竞争性自适应重加权算法(competitive adaptive reweighted sampling, CARS)进行全样本降维,其中,采样频率设置为 0.8,筛选阈值为 0.8,蒙特卡洛采样次数为 300,交互验证组为 15,筛选过程如图 8。

在图 8(a)和(b)中可以看到随着运行次数的增加,特征波长数量逐渐减少,RMSECV呈现先下降后上升的趋势,当在140次运行时 RMSECV到达最小值;图 8(c)表示特征波长变量回归系数的变化趋势,"*"表示 RMSECV最小的位置,CARS共筛选出特征波长39个,占全波段的6.12%,特征波长分别为430.04,445.81,448.06,448.81,449.56,472.09,472.84,509.64,534.42,538.17,625.28,626.78,627.53,703.38,749.19,749.94,755.19,756.70,757.45,767.21,767.96,797.25,804.76,805.51,807.01,812.27,823.53,830.29,831.04,831.79,832.54,833.29,840.05,843.05,873.09,892.62,909.89,928.66,936.17 nm。

2.3 识别模型评价

2.3.1 基于多种小波基离散变换降维模型评价

不同的小波基函数降维效果不同,为了获得最佳分类识别效果,选取 Daubechies 小波族中的 db1,Symlets 中的 sym2,Coiflets 中的 coifl,Biorthogonal 中的 bior2.2 和 ReverseBior中的 rbiol.5 分别对数据进行 $1\sim6$ 层小波变换后建立识别模型,建立流程如图 9 所示。样本划分采用 Kennard-Stone算法,样本总数的 75%作为训练集,25%作为预测集。

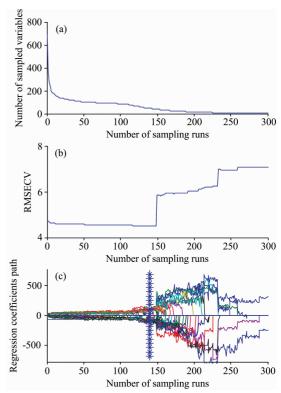


图 8 CARS 筛选特征波长过程

Fig. 8 Process of selecting characteristic wavelength by CARS

4 种算法的总体精度如图 10(a)—(d)所示。总体来看, 基于 CNN 和 MLP 算法的总体精度曲线平稳度均高于基于 KNN 和 SVM 算法,说明 CNN 和 MLP 算法学习与预测能 力较强,各算法总体精度随离散变换层数的增加成波浪式上 下浮动,经 bior2.2 降维后的总体精度高于其他。图 10(a)中 除 db1 和 rbio1.5 小波基外,其余小波基降维后基于 CNN 算法建模总体精度在 78.40%~91.20%之间波动;其中,经coif1 第 2 层变换时总体精度取得最优值为 91.20%;图 10 (b)中经 coif1 和 rbio1.5 第 4 层变换后 MLP 算法总体精度

均取得最优值为 83. 20%; 图 10(c)中经 sym2 第 2 层变换后 KNN 算法总体精度取得最优值为 66. 40%; 图 10(d)中经 bior2. 2 第 2 层变换后 SVM 算法总体精度取得最优值 为 90. 40%。

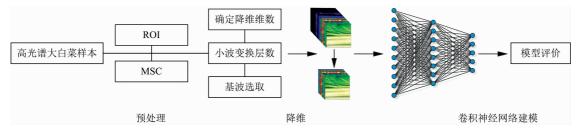


图 9 基于高光谱离散小波变换的卷积神经网络分类流程图

Fig. 9 Flow chart of hyperspectral image classification based on DWT and deep learning

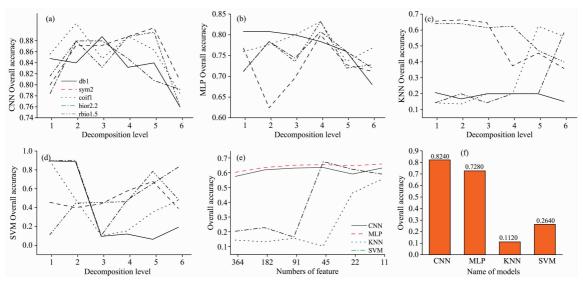


图 10 基于 DWT, PCA 和 CARS 降维的建模结果

- (a)—(d)分别为基于 DWT 降维的 CNN, MLP, KNN 和 SVM 模型总体精度;
- (e)基于 PCA 降维 4 种模型总体精度;(f)基于 CARS 降维 4 种模型总体精度

Fig. 10 Modeling results based on DWT, PCA and CARS

- (a)—(d) Overall accuracies of CNN, MLP, KNN and SVM models based on DWT;
- (e) Overall accuracies of four models based on PCA; (f) OAs of four models based on CARS

2.3.2 基于 PCA 和 CARS 降维模型评价

为充分验证本研究所提出的离散小波变换降维算法的可靠性,分别取 PCA 降维后前 364,182,91,45,22 和 11 个主成分(分别对应离散小波 1~6 层变换后的数据维度)进行建模,4 种算法的总体精度如图 10(e)所示。随着数据维度的减少,CNN 和 MLP 算法总体精度波动不大,但 KNN 和 SVM 算法的总体精度波动较大,相比而言 CNN 和 MLP 算法学习能力相对较强,模型稳定性较好。SVM 算法在取前45 个主成分时获得最优总体精度为 62.80%。经 CARS 降维后 4 种算法的总体精度如图 10(f)所示,CNN 取得该降维算法最高总体精度 82.40%,KNN 算法总体精度最低为11.20%,可见 KNN 算法不适合该类数据样本。

2.3.3 不同降维和建模算法横向评价

3种降维和4种建模算法总体精度和 Kappa 系数如表 3

所示。从整体来看在总样本未经降维过程的分类模型预测用时最长,精度不高;基于 CARS 降维算法分类总体精度最低;经 DWT 降维后的分类模型 KNN,SVM,MLP和 CNN总体精度分别为 66.40%,90.40%,83.20%和 91.20%。此外,经 DWT 降维后 4 种分类算法预测用时略高于其他 2 种降维算法。

不同算法的分类精度如表 4 所示, 从整体来看灭多威和乐果分类精度较低(分类精度分别为 92.00%和 96.00%), 其原因可能是两种药物分子式均含有类似的甲基, 导致光谱特征区分度较低; 毒死碑和氯氰菊酯分别在 CARS-SVM 和DWT(bior2.2-2)-SVM 算法取得最佳分类精度 100%, 说明SVM 识别分类能力较好; 乐果和无残留均在 DWT(coif1-2)-CNN 获得最高分类精度 100%, 说明 DWT-CNN 算法有较好的降维、特征提取和分类识别能力。

表 3 不同算法的总体精度和 Kappa 系数

Table 3 Overall accuracies and Kappa coefficients of different algorithms

	降维算法											
模型	None			CARS		PCA		DWT				
侠至	OA /%	Kappa	Time /ms	OA /%	Kappa	Time /ms	OA /%	Kappa	Time /ms	OA /%	Kappa ,	Time /ms
KNN	12.00	-0.10	16.98	11.20	-0.11	10.00	56.00	0.49	4.00	66.40	0.58	20.02
SVM	89.60	0.87	74.77	26.40	0.08	4.99	68.00	0.60	4.99	90.40	0.88	14.03
MLP	67.20	0.59	80.78	72.80	0.66	59.99	66.40	0.58	67.01	83.20	0.79	63.23
CNN	82.40	0.78	698.13	26.40	0.08	4.99	64.00	0.55	94.01	91.20	0.89	86.01

注: KNN 分别在 PCA(11)和 DWT(sym2-2)取得最优值, SVM 分别在 PCA(22)和 DWT(bior2. 2-2)取得最优值, MLP 分别在 PCA(45)和 DWT(coif1-4)取得最优值, CNN 分别在 PCA(22)和 DWT(coif1-2)取得最优值; 其中, PCA(n)表示基于 PCA 降维算法前 n 个主成分建模, DWT(W-g)表示基于 W 小波基离散第 g 层变换降维算法建模

Note: KNN reaches optimal values with PCA (11) and DWT (sym2-2); SVM reaches optimal values with PCA (22) and DWT (bior2. 2-2); MLP reaches optimal values with PCA (45) and DWT (coif1-4); and CNN reaches optimal values with PCA (22) and DWT (coif1-2); PCA (n) denotes the modeling based on the first n principal components, and DWT (W-g) represents the modeling based on the dimension reduction algorithm using discrete transform of g(th) layer W wavelet basis

表 4 不同算法的分类精度 Table 4 Overall accuracies of the various

prediction algorithms

降维	模型	药物种类							
算法		毒死蜱	氯氰菊酯	灭多威	乐果	无残留			
None		16.00	12.00	8.00	24.00	0.00			
CARS	KNN	16.00	12.00	4.00	20.00	4.00			
PCA		58.82	42.00	63.79	44.44	69.56			
DWT		60.00	80.00	48.00	64.00	80.00			
None	SVM	96.00	92.00	84.00	84.00	92.00			
CARS		100.00	8.00	20.00	4.00	0.00			
PCA		68.62	66.00	70.69	66.66	67.39			
DWT		96.00	100.00	80.00	84.00	92.00			
None	MLP	88.00	88.00	52.00	12.00	96.00			
CARS		56.00	52.00	92.00	72.00	92.00			
PCA		60.78	68.00	75.86	46.67	78.26			
DWT		88.00	84.00	72.00	76.00	96.00			
None	CNN	76.00	84.00	76.00	80.00	96.00			
CARS		76.00	80.00	76.00	80.00	100.00			
PCA		60.78	74.00	63.79	44.44	76.08			
DWT		88.00	88.00	84.00	96.00	100.00			

基于高光谱离散小波变换的卷积神经网络分类算法,对5组大白菜样本高光谱数据集进行分类识别,结果表明:

(1)经降维后的高光谱数据与未降维数据相比较,预测集总体精度、Kappa 均有明显提高,同时用时也大大缩短,说明降维算法能有效除去冗余数据降低维度,改善"休斯现象",提高建模算法精度。

(2)基于 coif1 小波基函数的离散小波算法通过多层低通滤波器能够有效过滤高频干扰信息,达到降维的效果,与PAC 和 CARS 降维算法相比较,基于离散小波变换降维数据的同时,不仅较好的保留原始光谱曲线形状,而且还能较好还原曲线相对空间位置,提高了高光谱数据分类识别准确度。

(3)卷积神经网络具有较强的特征抓取和学习能力,基于离散小波变换和卷积神经网络算法模型总体精度为91.20%,与MLP、SVM和KNN相比分别高出了8.00%,0.80%和24.80%,充分发挥了离散小波变换降维与卷积神经网络的优势。

本工作仅在单一农药残留基础上建立识别模型,为后期 实现便携式无损、快速检测大白菜农残设备研发提供一个新 的方法。下一步研究工作将侧重在混合农药残留的条件下构 建分类模型,并最大限度压缩模型参数量,缩短预测时间。

3 结 论

融合高光谱、离散小波变换和卷积神经网络提出了一种

References

- [1] LIU Chun-long, WANG Cheng, GUO Yu(刘春龙, 王 成, 郭 禹). Agriculture and Technology(农业与技术), 2019, 39(15): 42.
- [2] Zhu Xiaoyu, Li Wenjin, Wu Ruimei, et al. Spectrochimica Acta Part A; Molecular and Biomolecular Spectroscopy, 2021, 250; 119366.
- [3] LI Chun-yu, GE Xiao, JIN Yan-ting, et al(李春雨, 葛 啸, 金燕婷, 等). Agricultural Engineering(农业工程), 2019, 9(6): 33.
- [4] Sun Jun, Cong Sunli, Mao Hanping, et al. Journal of Food Process Engineering, 2018, 41(2): e12654.
- [5] JI Hai-yan, REN Zhan-qi, RAO Zhen-hong(吉海彦, 任占奇, 饶震红). Chinese Journal of Luminescence(发光学报), 2018, 39 (12); 1778.
- [6] XU Tong-yu, GUO Zhong-hui, YU Feng-hua, et al(许童羽, 郭忠辉, 于丰华, 等). Transactions of the Chinese Society of Agricultural

- Engineering(农业工程学报), 2020, 36(2): 209.
- [7] DENG Lai-fei, ZHANG Fei, QI Ya-xiao, et al(邓来飞,张 飞,齐亚霄,等). Spectroscopy and Spectral Analysis(光谱学与光谱分析), 2020, 40(1): 247.
- [8] SHI Yun, MA Dong-hui, LÜ Jie, et al(师 芸, 马东晖, 吕 杰, 等). Transactions of the Chinese Society of Agricultural Engineering(农业工程学报), 2020, 36(6): 151.
- [9] SUN Jun, ZHANG Mei-xia, MAO Han-ping, et al(孙 俊,张梅霞,毛罕平,等). Transactions of the Chinese Society for Agricultural Machinery(农业机械学报), 2015, 46(6); 251.

Identification of Pesticide Residue Types in Chinese Cabbage Based on Hyperspectral and Convolutional Neural Network

JIANG Rong-chang^{1,2}, GU Ming-sheng², ZHAO Qing-he¹, LI Xin-ran¹, SHEN Jing-xin^{1,3}, SU Zhong-bin^{1,4}

- 1. Institute of Electrical and Information, Northeast Agricultural University, Harbin 150030, China
- 2. Harbin City Data Center, Harbin 150030, China
- 3. Shandong Academy of Agricultural Machinery Sciences, Jinan 250100, China

Abstract Traditional chemical detection methods for analyzing pesticide residues in chinese cabbage are slow and destructive. In this study, a rapid, non-destructive method for identifying the types of pesticide residues in chinese cabbage samples was developed. First, the hyperspectral imaging system was used to analyze chinese cabbage samples exposed to one of four pesticides chlorpyrifos, dimethoate, methomyl and cypermethrin. The pesticide concentration ratios were 0.10, 1.00, 0.20 and 2.00 mg · kg⁻¹, respectively; and the data was compared to a pesticide-free sample. After 12 hours of natural degradation at room temperature, a hyperspectral imaging system corrected by a black and white plate was used to obtain $400 \sim 1~000~\text{nm}$ hyperspectral images of chinese cabbage samples, and the target area was selected by ENVI software. The specific regions of interest (ROI) in samples were further investigated, and the pre-processing by multiple scattering correction (MSC). Secondly, three algorithms such as competitive adaptive reweighting algorithm (CARS), principal component analysis (PCA), discrete wavelet transform (DWT) (based on db1, sym2, coif1, bior2.2, and rbio1.5 wave base functions) were then used to screen for dimensionality reduction from optimally pre-processed results. Finally, the screening results and the samples divided by the Kennard-Stone algorithm were adopted to construct three recognition models separately. Such as k-nearest-neighbor (KNN), support vector machine (SVM), multilayer perceptron (MLP) and convolutional neural network (CNN) were used to determine the best screening method for the dimension of pesticide residues and the optimal hyperspectral recognition model. Our results showed that the CNN, MLP, KNN, and SVM algorithms achieve the best overall accuracy (91.20%, 83.20%, 66.40%, and 90.40%, respectively), Kappa coefficient (0.89, 0.79, 0.58, and 0.88), and the prediction set time (86.01, 63.23, 20.02 and 14.03 ms) under the dimensionality reduction algorithm DWT, respectively; the wavelet basis function and the number of transform layers are coif1-2, coif1-4, bior2, 2-2 and sym2-2. All three indicators are better than the modeling results based on CARS and PCA dimensionality reduction algorithms. It showed that the combination of discrete wavelet transform and convolutional neural network shortens the time of classification and identification and significantly improves the classification and identification accuracy, and improves the Hughes phenomenon, providing a new method for non-destructive and rapid detection and identification of chinese cabbage pesticide residues.

Keywords Hyperspectral; Chinese cabbage; Identification of pesticide residues; Discrete wavelet transform; Convolutional neural network(CNN)

(Received Aug. 3, 2021; accepted Oct. 31, 2021)