

# 基于荧光光谱结合宽度学习的白菜农药残留量检测方法

刘翠玲<sup>1,2</sup> 李佳琮<sup>1,2</sup> 孙晓荣<sup>1,2</sup> 殷莺倩<sup>1,2</sup> 张善哲<sup>1,2</sup> 吴静珠<sup>1,2</sup>

(1. 北京工商大学人工智能学院, 北京 100048;

2. 北京工商大学食品安全大数据技术北京市重点实验室, 北京 100048)

**摘要:**为了高效监控蔬菜中农药残留情况,利用荧光光谱技术检测白菜中吡虫啉农药残留量。首先通过三维荧光光谱确定400nm为吡虫啉的最佳激发波长;其次通过分析6种预处理算法和2种降维算法,分别选出多元散射校正(Multiple scattering calibration, MSC)和无信息变量消除(Uninformative variable elimination, UVE)作为最佳的预处理与波长选择方法;宽度学习系统(Broad learning system, BLS)用于荧光光谱建模,同时与偏最小二乘回归(Partial least squares regression, PLSR)、支持向量机(Support vector machine, SVM)和深度极限学习机(Deep extreme learning machines, DELM)等经典模型进行比较。结果显示BLS模型获得了最佳吡虫啉含量预测效果,测试集决定系数 $R_p^2$ 达0.949,均方根误差(Root mean square error, RMSE)达0.347 mg/kg。表明了荧光光谱技术结合宽度学习预测农药残留量的可行性,可以为在线检测农药残留量系统的开发提供理论依据。

**关键词:**白菜;农药残留;三维荧光光谱;宽度学习系统;波段选择

中图分类号:S237 文献标识码:A 文章编号:1000-1298(2023)10-0198-07

OSID:



## Detection of Pesticide Residues in Cabbage Based on Fluorescence Spectroscopy Combined with Broad Learning

LIU Cuiling<sup>1,2</sup> LI Jiacong<sup>1,2</sup> SUN Xiaorong<sup>1,2</sup> YIN Yingqian<sup>1,2</sup> ZHANG Shanzhe<sup>1,2</sup> WU Jingzhu<sup>1,2</sup>

(1. School of Artificial Intelligence, Beijing Technology and Business University, Beijing 100048, China

2. Beijing Key Laboratory of Big Data Technology for Food Safety, Beijing Technology and Business University, Beijing 100048, China)

**Abstract:** In order to efficiently monitor the pesticide residues in vegetables, a detection method of pesticide residue content of imidacloprid in cabbage on fluorescence spectroscopy was proposed. Firstly, 400 nm was determined of as the optimal excitation wavelength of imidacloprid by three-dimensional fluorescence spectroscopy. Afterwards, six pre-processing algorithms and two dimensionality reduction algorithms were analyzed. Multiple scattering calibration (MSC) and uninformative variable elimination (UVE) were selected as the best pre-processing and wavelength selection methods, respectively. Finally, the broad learning system (BLS) was used for fluorescence spectroscopy modeling and compared with classical models such as partial least squares regression (PLSR), support vector machine (SVM), and deep extreme learning machines (DELM). The results showed that the BLS model obtained the best prediction of imidacloprid content. The test set coefficient of determination ( $R_p^2$ ) reached 0.949 and the root mean square error (RMSE) reached 0.347 mg/kg. The research result showed that fluorescence spectroscopy combined with BLS was feasible to identify pesticide residue content, and it can provide a theoretical basis for the development of online detection system for pesticide residue content.

**Key words:** cabbage; pesticide residue; three-dimensional fluorescence spectroscopy; broad learning system; wave selection

## 0 引言

实际农作物生产中对农药的过分依赖及不合理

使用,会导致农药残留,危害人类的身体健康<sup>[1]</sup>。随着生活水平的逐渐提高,人们也越发重视食品安全、健康、环保等问题。因此,对常食蔬菜中的农药

残留量进行检测十分重要。目前,国内外常用的农药残留检测主要采用气相色谱法、高效液相色谱法等<sup>[2-3]</sup>。这些方法适应范围广,但操作的过程相对复杂、效率低,无法实现现场快捷、有效检验。

近年来,相关学者利用典型的光谱技术对农产品中农药残留进行了研究。张瑛等<sup>[4]</sup>采用太赫兹光谱检测大米中沙蚕毒素类农药残留,相关系数达 0.9599。然而,太赫兹等红外光谱对极性化学键的信号比较强,不适宜对含水样本进行检测。CHEN 等<sup>[5]</sup>将偏最小二乘法 (Partial least squares regression, PLSR) 应用于表面增强拉曼光谱技术定量检测乌龙茶中多菌灵含量,决定系数达 0.964。LIU 等<sup>[6]</sup>采用 PLSR 成功构建了茶叶中苯醚甲环唑的表面增强拉曼光谱测定模型,相关系数达 0.97。但常见的拉曼光谱由于散射强度较小,需要利用繁琐的前处理才能对农药残留等痕量精准检测。

荧光光谱技术具有灵敏度高、选择性好、价格低廉等优势,目前在农药含量检测领域飞速发展。GUO 等<sup>[7]</sup>利用荧光光谱检测水中的西维因和百菌清浓度。JI 等<sup>[8]</sup>采用 PLSR 构建了水中生霉素、多效唑、博斯卡利等多种农药含量检测模型,决定系数达 0.98。然而,荧光技术现有研究集中于检测水溶液中的农药,对蔬菜中农药残留量的检测较少。宽度学习系统 (Broad learning system, BLS) 是 CHEN 等<sup>[9]</sup>近年来提出的一种有效解决小样本训练问题的新型算法。MA 等<sup>[10]</sup>应用 BLS 对高光谱遥感图像进行分类;乔继红等<sup>[11]</sup>利用 BLS 与近红外光谱,构建了国外奶粉的判别模型。然而,现有研究局限于应用 BLS 进行分类,且鲜有研究将该模型迁移至其它光谱检测领域。该算法呈扁平结构,横向扩展,具有迭代收敛速度快、泛化能力强等优势。在经过大量调研与理论研究后,尝试在荧光光谱技术检测白菜中吡虫啉残留的定量研究中,引入宽度学习系统。

吡虫啉是一种新烟碱类杀虫剂,因其高效、低廉等优点,被广泛应用于农作物生产种植中。本文以白菜中吡虫啉残留为研究对象,利用荧光光谱技术结合不同数据处理方法测定吡虫啉农药残留量。将 BLS 引入荧光光谱的数据建模,并与线性模型 PLSR、非线性模型支持向量机 (Support vector machine, SVM) 以及深度极限学习机 (Deep extreme learning machines, DELM) 进行对比分析,验证 BLS 在荧光光谱数据分析的可行性,并获得吡虫啉含量的最优检测模型,拟为开发在线检测蔬菜中农药残留量系统提供理论依据。

## 1 材料与方法

### 1.1 样本制备

选用 20% 的可溶性农药吡虫啉(市售,深圳诺普信农化股份有限公司)。将市购的普通大白菜用去离子水洗净晾干后粉碎,通过砂芯过滤获取蔬菜汁液为背景溶剂,将农药与蔬菜汁经涡旋混合器充分混匀。配制出吡虫啉(国标要求最大残留量 0.2 mg/kg)质量比为 0~5 mg/kg 的 13 个梯度样本总计 130 个。该质量比范围分布在国标规定最大残留量附近,具有实际意义。

### 1.2 实验仪器与其采集参数

使用爱丁堡 FS5 型荧光光谱仪(英国),采集 130 个样品的荧光光谱。荧光光谱的激发光源选用脉冲氙灯,光电检测器选用 PMT-900 型光电倍增管。三维荧光光谱采集,设置激发波长间隔为 10 nm,发射波长间隔为 2 nm,激发波长  $\lambda_{Ex}$  为 350~550 nm,发射波长  $\lambda_{Em}$  为 400~600 nm。荧光发射光谱采集,设置采集步长为 3 nm,采集范围为 430~610 nm。

### 1.3 数据分析方法

#### 1.3.1 样本划分

在模型校准中,样本被分为校准集和预测集,使用基于联合  $x-y$  距离 (SPXY) 的样本集分区的样本分配方法,该方法考虑样本光谱和样本参考值的差异<sup>[12]</sup>。将样本按照比例 3:1 划分校正集和预测集。其中,校正集与预测集分别包含 97 个和 33 个样本用于构建白菜中吡虫啉含量预测模型。数据划分具体情况如表 1 所示,校正集的吡虫啉含量涵盖预测集的范围,说明校正集可以建立稳健的校正模型,且预测集可以有效对模型进行预测。

表 1 样本数据集划分

Tab. 1 Data set division of sample

数据集	样本数量	白菜中吡虫啉质量比/(mg·kg <sup>-1</sup> )		
		范围	平均值	标准偏差
校正集	97	0.01~5	0.923	1.45
预测集	33	0.01~5	0.986	1.54

#### 1.3.2 光谱预处理

由于使用荧光光谱仪所获取的数据信号除了含被测样本待测成分信息外,还包括各种仪器的噪声,如高频随机噪声、基线漂移、杂散信息、样本背景等无关信息<sup>[13]</sup>。因此,采用合适的光谱预处理方法可以提取有效的光谱信息,提升光谱质量。在全光谱范围内使用一阶导数 (First-order derivative, D1)、二阶导数 (Second-order derivatives, D2)、标准正态变

换(Standard normal variable, SNV)、S-G 卷积平滑(Savitzky-Golay, S-G)、多元散射校正(Multiple scattering calibration, MSC)以及连续小波变换(Continuous wavelet transforms, CWT)6 种方法对原始光谱数据进行预处理。D1 和 D2 是光谱分析中常用的基线校正和光谱分辨预处理方法,倒数光谱可以有效地消除其他背景的干扰,提高分辨率和灵敏度<sup>[14]</sup>。SNV 通过单独对每个样本的光谱进行校正,使其每个波段的吸光度均符合正态分布<sup>[15]</sup>。S-G 卷积平滑法通过多项式来对移动窗口内的数据进行多项式最小二乘拟合,其实质是一种加权平均法<sup>[16]</sup>。MSC 通过减少样本间的基线偏移,使其能够充分保留样本中与白菜吡虫啉相关的光谱吸收信息<sup>[17]</sup>。CWT 是一种时频变换方法,较适用于分析非平稳信号<sup>[18]</sup>。

### 1.3.3 光谱特征提取

核主成分分析(Kernel principal component analysis, KPCA)是对主成分分析(Principal components analysis, PCA)算法的非线性扩展。PCA 降维原理是基于线性分析理论,而 KPCA 是在 PCA 的理论基础上采用非线性核函数 Kernel 参与数据分析,因此能够挖掘到数据集中蕴含的非线性关系<sup>[19]</sup>。无信息变量消除(Uninformative variable elimination, UVE)可以避免过度拟合,提高模型的预测能力。在这种方法中,通过向原始变量添加人工随机变量来获得一个新的数据集。模型通过留一交叉验证进行优化。因此,重要性低于人工随机变量的谱系变量被删除<sup>[20]</sup>。

### 1.3.4 BLS 模型

宽度学习系统(BLS)是基于随机向量函数链接网络(RVFLNN)的一种具有通用逼近能力的新型建模方法<sup>[21]</sup>,具体结构如图 1 所示。

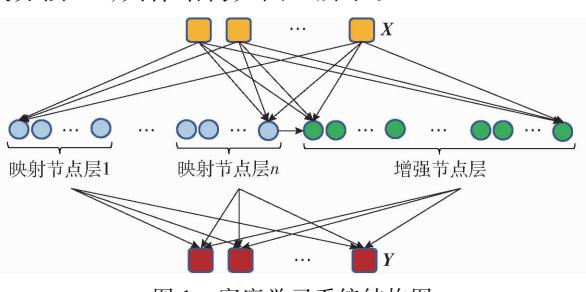


图 1 宽度学习系统结构图

Fig. 1 Broad learning system structure diagram

BLS 隐藏层的输入矩阵是由映射节点层(Mapped feature)和增强节点层(Enhancement nodes)组成,系统第  $i$  组映射特征及其构成的集合  $Z_i$  可表示为

$$Z_i = \varphi_i(\mathbf{W}_{ei}X + \boldsymbol{\beta}_{ei}) \quad (i=1,2,\dots,n) \quad (1)$$

$$\mathbf{Z}^n = [\mathbf{Z}_1 \quad \mathbf{Z}_2 \quad \dots \quad \mathbf{Z}_n] \quad (2)$$

式中  $\varphi_i(\cdot)$ ——特征映射函数

$\mathbf{W}_{ei}$ ——第  $i$  个最佳权值向量

$\boldsymbol{\beta}_{ei}$ ——对应于  $\mathbf{W}_{ei}$  的偏置向量

$\mathbf{Z}^n$ ——特征节点

$X$ ——BLS 模型的输入矩阵

增强节点是映射节点通过相同映射与非线性激活得到的,其中系统第  $j$  个增强节点及其构成的集合  $H_j$  可表示为

$$H_j = \delta_j(\mathbf{W}_{hj}\mathbf{Z}^n + \boldsymbol{\beta}_{hj}) \quad (j=1,2,\dots,d) \quad (3)$$

$$\mathbf{H}^d = [H_1 \quad H_2 \quad \dots \quad H_d] \quad (4)$$

式中  $\delta_j$ ——映射激活函数

$H^d$ ——增强节点

$\mathbf{W}_{hj}, \boldsymbol{\beta}_{hj}$ ——特征映射至增强节点的权值向量和偏置向量

白菜中吡虫啉含量的预测值是将输出权值矩阵通过回归广义逆计算得到的,计算过程可表示为

$$\mathbf{Y} = [\mathbf{Z}^n | \mathbf{H}^d] \mathbf{W} \quad (5)$$

式中  $[\mathbf{Z}^n | \mathbf{H}^d]$ ——宽度学习系统输入

$\mathbf{W}$ ——从特征节点到增强节点再到系统输出的权值矩阵

$\mathbf{Y}$ ——吡虫啉含量预测值

### 1.3.5 模型评价

选择决定系数(Coefficient of determination,  $R^2$ )和均方根误差(Root mean square error, RMSE)作为白菜中吡虫啉农药残留含量检测模型的评价参数。 $R^2$ 越接近 1,表明荧光光谱信息与白菜中吡虫啉的相关性越好,RMSE 越小,表明预测中产生的误差越小,即光谱建模效果越好<sup>[22]</sup>。

## 2 结果与分析

### 2.1 三维荧光光谱采集结果

为了获得吡虫啉农药的最佳激发波长,吸取 5 mL 纯农药并扫描其三维荧光光谱。图 2 为吡虫啉溶液三维荧光光谱图和对应的等高线图,可以看出,在  $\lambda_{Ex}, \lambda_{Em}$  为 400、480 nm 存在一个荧光峰,所以吡虫啉溶液的最佳激发波长为 400 nm,最佳发射波长为 480 nm。

### 2.2 荧光发射光谱采集结果

选用吡虫啉溶液的最佳激发波长 400 nm,扫描白菜中农残溶液的荧光发射光谱,共得到波段数为 61 维的光谱数据。为了更清晰地分析不同浓度农残样本的光谱差异,将各质量比下的 10 组数据取平均,并绘制图 3 中的质量比变化对比曲线。可以看出,随着白菜汁中吡虫啉质量比的增加,对应的荧光强度也随之增长。在波长 490 nm 和 580 nm 处分别

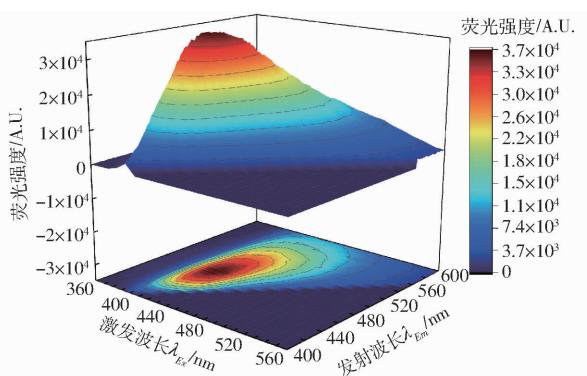


图 2 寻找吡虫啉最佳激发波长的三维荧光光谱图

Fig. 2 Three-dimensional fluorescence spectra for finding optimal excitation wavelength of imidacloprid

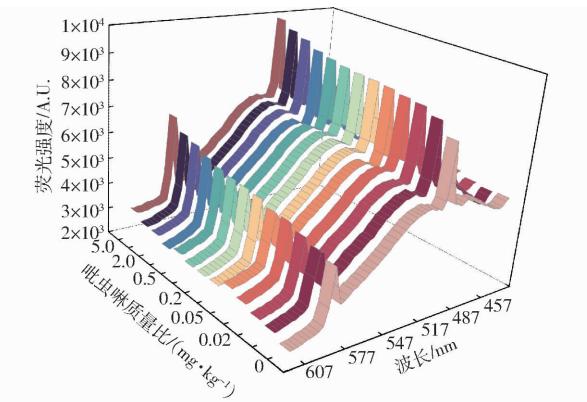


图 3 不同吡虫啉质量比的平均发射荧光光谱

Fig. 3 Mean emission fluorescence spectra of different imidacloprid mass ratios

存在 2 个尖峰, 对应表示为青光和黄光。通过分析发现荧光光谱信息与样本中农药含量存在规律变化, 因此理论上可以通过荧光数据表征白菜汁中吡虫啉的含量。

### 2.3 数据预处理结果

将原始光谱数据与经 6 种方法 (D1、D2、SNV、S-G、MSC、CWT) 预处理后的光谱数据分别建立 BLS 模型。表 2 为光谱数据的建模结果, RMSEC 为校正集均方根误差, RMSEP 为测试集均方根误差。其中 D1 和 D2 处理使得  $R_p^2$  下降, 表明这两种方法并不适用于农残样本的荧光光谱数据。SNV、S-G、

表 2 不同预处理的建模结果

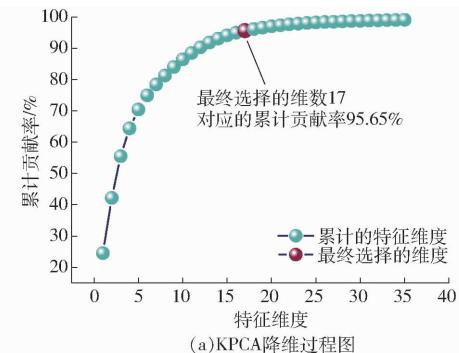
Tab. 2 Modeling results with different pre-processing

模型	校正集		测试集	
	$R_c^2$	RMSEC/ ( $\text{mg} \cdot \text{kg}^{-1}$ )	$R_p^2$	RMSEP/ ( $\text{mg} \cdot \text{kg}^{-1}$ )
D1	0.805	0.637	0.785	0.657
D2	0.822	0.619	0.799	0.648
SNV	0.856	0.588	0.833	0.602
S-G	0.884	0.525	0.864	0.557
MSC	0.902	0.448	0.879	0.532
CWT	0.878	0.534	0.859	0.583
无预处理	0.838	0.599	0.829	0.614

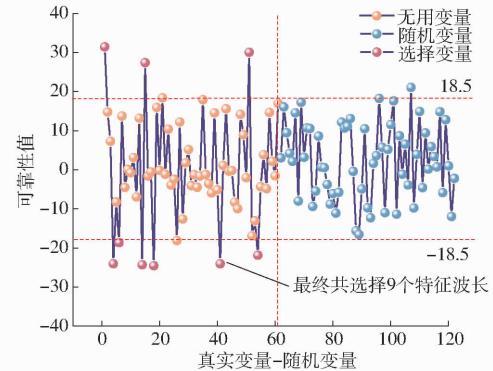
MSC 和 CWT 都可以提高模型决定系数, 其中基于 MSC 预处理的光谱数据建模结果最佳, 测试集  $R_p^2$  达 0.879, 与无预处理相比决定系数提高 0.05。说明 MSC 更能有效压缩光谱数据集并消除噪声和杂散光等干扰。因此选择 MSC 预处理后的光谱数据作为后续分析的基础。

### 2.4 光谱特征降维结果

农药残留样品的成分复杂, 光谱信息量大, 通过特征降维可以简化模型, 提高预测的稳定性。图 4a 为 KPCA 的降维过程图, 成分数累计到第 17 维时累计贡献率增长趋于平稳, 此时累计贡献率为 95.65%。说明前 17 维数据已包含了大部分有效信息, 故选择前 17 维主成分量当作预测模型输入维主成分量。



(a) KPCA 降维过程图



(b) UVE 变量选择过程图

Fig. 4 Diagrams of spectral feature downscaling process

在添加噪声后, UVE 根据光谱变量和噪声组成的自变量矩阵, 对目标矩阵回归系数的统计分布进行变量判断。图 4b 为 UVE 的变量选择过程中的加噪筛选过程曲线图, 图中左侧曲线为农药残留样品的光谱变量矩阵, 右侧为添加与光谱变量数目相同的随机噪声矩阵, 2 条水平虚线表示随机噪声的最大和最小阈值, 两线之间为剔除的无关变量。最终通过 UVE 选择出 9 个特征波长。

### 2.5 基于 BLS 的吡虫啉含量预测结果

白菜中吡虫啉残留样本的光谱数据采用最佳预

处理方法 MSC, 然后分别进行 KPCA 和 UVE 特征降维, 依次将降维后的 17 维与 9 维光谱数据送入 BLS 模型。BLS 模型的参数为特征窗口数量  $n$ 、窗口内的特征数量  $k$  以及增强节点数目  $m$ 。实验选用 Leaky ReLU 为 BLS 的激活函数, 参数设置  $n = 10$ ,  $k = 30$ ,  $m = 300$ 。表 3 为基于全波段、KPCA 特征和 UVE 特征的 BLS 模型的建模结果。可以看出, 2 种降维方式均能有效提升模型精度, 说明全波段光谱存在冗余信息, 数据集的压缩能够精炼出与农药残留量相关性的光谱信息。其中, 基于 UVE-BLS 组合模型的预测结果最佳, 图 5a 显示了该模型真实值与预测值的线性拟合结果, 校正集与测试集决定系数分别为 0.970 和 0.949。此外, UVE-BLS 组合模型相比全波段建模的测试集决定系数增加 0.07, 均方根误差降低 0.185 mg/kg, 说明 UVE 所提取的特征波段最能表征白菜中吡虫啉的含量, 这种通过添加噪声来消除不提供信息变量的方式适用于荧光光谱检测农药残留量。图 5b 更加清晰地展示了预测集的样本分布以及吡虫啉含量真实值和预测值的偏差, 可以看出当农药质量比低于 1 mg/kg 时, 预测偏差较小, 预测值均分布在真实值附近。当质量比远超国家标准 0.2 mg/kg 时, 模型稳定性有所下降, 预测结果虽然出现明显浮动, 但也始终保持了正确判别农药残留量超标的基础。综上所述, 荧光光谱法结合 BLS 模型监测白菜中吡虫啉含量是可行的, UVE 所选择的特征波长可作为表征农药残留量的光谱特征。

表 3 不同降维方法的 BLS 模型结果

Tab. 3 Results of BLS models with different dimensionality reduction methods

降维方法	特征数	校正集		测试集	
		$R_c^2$	RMSEC/(mg·kg <sup>-1</sup> )	$R_p^2$	RMSEP/(mg·kg <sup>-1</sup> )
无	61	0.902	0.448	0.879	0.532
KPCA	17	0.951	0.331	0.920	0.430
UVE	9	0.970	0.224	0.949	0.347

## 2.6 与其它数据建模算法比较

为了评估 BLS 算法建立荧光光谱预测白菜中吡虫啉含量的性能, 将基于最优特征波长 UVE 建模的 BLS 模型与经典线性机器学习模型 (PLSR)、经典非线性模型 (SVM) 以及基于深度学习的改进非线性模型 (DELM) 进行对比分析。本研究中 PLSR 的可调参数为主成分数, 决定了建模分析的变量个数, 该参数的最优取值均采用二十折交叉验证获得<sup>[23]</sup>; SVM 采用 RBF 核函数, 通过设置惩罚因子  $c$  和核函数参数  $g$  调节模型精度<sup>[24]</sup>; DELM 模型设置

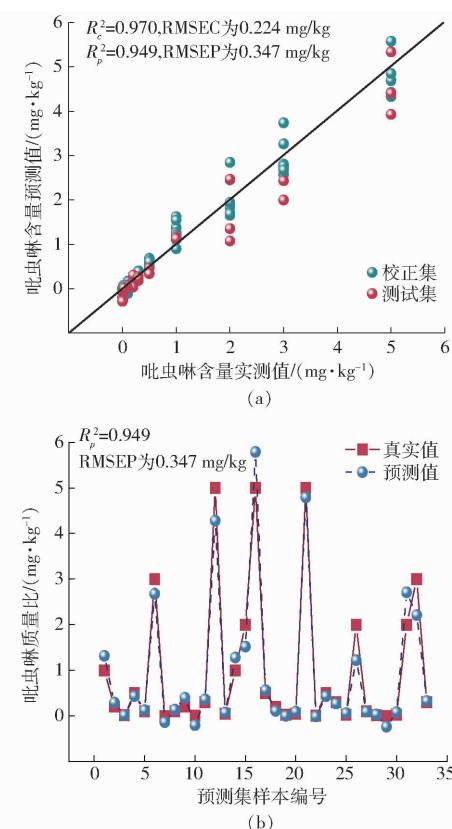


图 5 UVE-BLS 建模结果

Fig. 5 Diagrams of UVE-BLS modeling results

sigmoid 为激活函数, 可调参数为 3 个隐含层的节点数<sup>[25]</sup>。由表 4 可以看出, 非线性模型的预测精度均优于 PLSR, 说明光谱信息与农药浓度之间的关系较复杂, 并不能通过线性关系表征二者的联系。其次, 实验表明 BLS 模型的准确度最高, 能够针对数据特征不多的小样本进行较为精准预测, 证实了 BLS 模型在光谱检测食品含量领域的可行性。分析 BLS 模型优于其他模型的原因, 可能是因为 BLS 模型是一种新型的不依赖深度结构的宽度神经网络, 该算法提升网络精度的方式就是通过横向增加“宽度”, 与深度学习模型的增加层数相比, BLS 能有效避免过度学习<sup>[26-27]</sup>。与线性模型相比, 它又能很好地拟合非线性数据。实际预测中 BLS 能通过逐渐逼近的方式, 不断提升预测精度, 使其正确性满足精度要求<sup>[28]</sup>。

表 4 不同建模算法的结果

Tab. 4 Results of different modeling algorithms

模型	模型参数	校正集		测试集	
		$R_c^2$	RMSEC/(mg·kg <sup>-1</sup> )	$R_p^2$	RMSEP/(mg·kg <sup>-1</sup> )
PLSR	9	0.895	0.491	0.885	0.519
SVM	4, 23, 6, 78	0.957	0.327	0.931	0.365
DELM	15, 20, 20	0.926	0.408	0.901	0.450
BLS	10, 30, 300	0.970	0.224	0.949	0.347

### 3 结论

(1) 利用三维荧光光谱测定吡虫啉,在波长 400 nm 激发和波长 480 nm 发射处呈现荧光特征峰。

(2) 结合 D1、D2、SNV、S-G、MSC、CWT 共 6 种算法分别对原始光谱数据进行预处理。相较而言, 基于 MSC 的预处理效果最佳。

(3) 基于 KPCA 和 UVE 分别得到了 17、9 个特征变量, 2 种降维方法均有效剔除了与建模相关度低的光谱波段, 提高了信噪比与后期建模的精度。

其中, UVE 算法消除冗余变量的性能最佳。

(4) 为了评估 BLS 模型的性能, 对比了线性算法(PLSR)和非线性算法(SVM、DELM)的建模结果。结果表明 BLS 模型具有较强的拟合能力, 测试集  $R_p^2$  达 0.949, RMSEP 达 0.347 mg/kg, 可快速预测吡虫啉的含量。

(5) 研究结果表明荧光光谱技术检测白菜中吡虫啉含量是可行的, 验证了 BLS 模型在光谱检测领域的适应性。该方法可为在线检测农药残留量系统的开发提供理论依据。

### 参 考 文 献

- [1] 徐霞红, 权浩然, 何开雨, 等. 农田环境中农药残留比例型荧光传感系统研究[J]. 农业机械学报, 2020, 51(11): 229–234.  
XU Xiaohong, QUAN Haoran, HE Kaiyu, et al. Research on proportional fluorescence sensing system for pesticide residues in farmland environment [J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(11): 229–234. (in Chinese)
- [2] 李常雄, 邹海民, 胡晓科, 等. 超高效液相色谱法测定果蔬中 4 种双酰肼类农药残留[J]. 中国测试, 2020, 46(3): 59–63.  
LI Changxiong, ZOU Haimin, HU Xiaoke, et al. UHPLC determination of four diacylhydrazide pesticides residues in fruits and vegetables [J]. China Measurement & Test, 2020, 46(3): 59–63. (in Chinese)
- [3] 吴南村, 张群, 李春丽, 等. 分散固相萃取结合气相串联质谱法检测黑胡椒中 19 种农药残留[J]. 南方农业学报, 2019, 50(3): 656–661.  
WU Nancun, ZHANG Qun, LI Chunli, et al. Determination of 19 pesticide residues in black pepper by dispersive solid phase extraction combined with gas tandem mass spectrometry [J]. Journal of Southern Agriculture, 2019, 50(3): 656–661. (in Chinese)
- [4] 张瑛, 吴静珠, 刘慧琳. 太赫兹光谱技术快速识别与检测大米中沙蚕毒素类农药残留[J]. 中国食品学报, 2022, 22(9): 217–225.  
ZHANG Ying, WU Jingzhu, LIU Huilin. Rapid identification and detection of Sarcotoxin-like pesticide residues in rice by terahertz spectroscopy [J]. Journal of Chinese Institute of Food Science and Technology, 2022, 22(9): 217–225. (in Chinese)
- [5] CHEN X, LIN M, SUN L, et al. Detection and quantification of carbendazim in Oolong tea by surface-enhanced Raman spectroscopy and gold nanoparticle substrates [J]. Food Chemistry, 2019, 293: 271–277.
- [6] LIU P, WU R, LI H, et al. Exploring variables optimization methods to screen surface-enhanced Raman spectroscopy characteristic peaks for rapid detection of difenoconazole pesticides in tea [J]. Vibrational Spectroscopy, 2022, 123: 103448.
- [7] GUO Z, LIU C, YANG R, et al. Detection of pesticide in water using two-dimensional fluorescence correlation spectroscopy and N-way partial least squares [J]. Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy, 2020, 229: 117981.
- [8] JI R, MA S, YAO H, et al. Multiple kinds of pesticide residue detection using fluorescence spectroscopy combined with partial least-squares models [J]. Applied Optics, 2020, 59(6): 1524–1528.
- [9] CHEN C, LIU Z. Broad learning system: an effective and efficient incremental learning system without the need for deep architecture [J]. IEEE Transactions on Neural Networks and Learning Systems, 2017, 29(1): 10–24.
- [10] MA Y, LIU Z. Hybrid spatial-spectral feature in broad learning system for hyperspectral image classification [J]. Applied Intelligence, 2022, 52: 2801–2812.
- [11] 乔继红, 苑希岩, 吴静珠, 等. 近红外光谱技术结合宽度学习系统识别国外奶粉产地[J]. 食品安全质量检测学报, 2023, 14(5): 9–15.  
QIAO Jihong, YUAN Xiyan, WU Jingzhu, et al. Near-infrared spectroscopy technology combined with broad learning system to identify the origin of foreign milk powder [J]. Journal of Food Safety & Quality, 2023, 14(5): 9–15. (in Chinese)
- [12] HAN T, LINNA Z, MING L, et al. Weighted SPXY method for calibration set selection for composition analysis based on near-infrared spectroscopy [J]. Infrared Physics & Technology, 2018, 95: 88–92.
- [13] 赵茂程, 吴泽本, 汪希伟, 等. 基于光谱成像的猪肉新鲜度空间分布预测评价方法[J]. 农业机械学报, 2022, 53(3): 412–422.  
ZHAO Maocheng, WU Zeben, WANG Xiwei, et al. Evaluation of spatial imaging-based spatial predictions of freshness spatial distribution over pork [J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(3): 412–422. (in Chinese)
- [14] WANG G, HUANG A M, HU X, et al. Discrimination of bamboo fiber and ramie fiber by near infrared spectroscopy [J]. Spectroscopy and Spectral Analysis, 2010, 30(9): 2365–2367.
- [15] 李杰, 李尚科, 蒋立文, 等. 基于近红外光谱技术与化学计量学的绿茶无损鉴别方法研究 [J]. 分析测试学报, 2020,

- 39(11) : 1344 – 1350.
- LI Jie, LI Shangke, JIANG Liwen, et al. A nondestructive method identifying varieties of green tea based on near infrared spectroscopy and chemometrics[J]. Journal of Instrumental Analysis, 2020, 39(11) : 1344 – 1350. (in Chinese)
- [16] ZHAO A, TANG X, ZHANG Z, et al. Optimizing Savitzky-Golay parameters and its smoothing pretreatment for FTIR gas spectra[J]. Journal of Instrumental Analysis, 2016, 36(5) : 1340 – 1344.
- [17] WU Y, PENG S, XIE Q, et al. An improved weighted multiplicative scatter correction algorithm with the use of variable selection: application to near-infrared spectra[J]. Chemometrics and Intelligent Laboratory Systems, 2019, 185(1) : 114 – 121.
- [18] USTUNDAG O, DINC E. Continuous wavelet transforms and ultra performance liquid chromatography applied to the simultaneous quantitative determination of candesartan cilexetil and hydrochlorothiazide in tablets[J]. Monatshefte fur Chemie, 2021, 52: 1097 – 1106.
- [19] XU Y, ZHANG D, SONG F, et al. A method for speeding up feature extraction based on KPCA[J]. Neurocomputing, 2007, 70(4) : 1056 – 1061.
- [20] CENTNER V, MASSART D L. Elimination of uninformative variables for multivariate calibration[J]. Anal. Chem., 1996, 68 : 3851 – 3858.
- [21] 叶荣珂,孔庆辰,李道亮,等.宽度学习的虾新鲜度检测方法[J].光谱学与光谱分析,2022, 42(1) : 164 – 169.  
YE Rongke, KONG Qingchen, LI Daoliang, et al. Shrimp freshness detection method based on broad learning system[J]. Spectroscopy and Spectral Analysis, 2022, 42(1) : 164 – 169. (in Chinese)
- [22] 褚小立. 化学计量学方法与分子光谱分析技术[M]. 北京: 化学工业出版社, 2011.
- [23] CHEN J, SUN D. Partial least squares regression (PLSR) applied to NIR and HSI spectral data modeling to predict chemical properties of fish muscle[J]. Food Engineering Reviews, 2017, 9(1) : 36 – 49.
- [24] CERVANTES F, GARCIA-LAMONT L, RODRIGUEZ-MAZAHUA A. A comprehensive survey on support vector machine classification: applications, challenges and trends[J]. Neurocomputing, 2020, 408 : 189 – 215.
- [25] JIA J, YUAN S, SHI Y, et al. Improved sparrow search algorithm optimization deep extreme learning machine for lithium-ion battery state-of-health prediction[J]. iScience, 2022, 25(4) : 103988 – 104005.
- [26] JIN J, LIU Z, CHEN C. Discriminative graph regularized broad learning system for image recognition[J]. Science China Information Sciences, 2018, 61(11) : 1 – 14.
- [27] 李国强,徐立庄.局部感受野的宽度学习算法及其应用[J].计算机工程与应用,2020,56(9) : 162 – 167.  
LI Guoqiang, XU Lizhuang. Application of local receptive field based broad learning system[J]. Computer Engineering and Applications, 2020, 56(9) : 162 – 167. (in Chinese)
- [28] DU J, VONG C M, CHEN C P. Novel efficient RNN and LSTM-like architectures: recurrent and gated broad learning systems and their applications for text classification[J]. IEEE Transactions on Cybernetics, 2020, 51(3) : 1586 – 1597.

(上接第 197 页)

- [28] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. YOLOv4: optimal speed and accuracy of object detection [J]. arXiv Preprint, arXiv:2004.10934, 2020.
- [29] WANG C Y, BOCHKOVSKIY A, LIAO H Y M. YOLOv7: trainable bag-of-freebies sets new state-of-the-art for real-time object detectors[J]. arXiv Preprint, arXiv:2207.02696, 2022.
- [30] LIU Z, LIN Y, CAO Y, et al. Swin transformer: hierarchical vision transformer using shifted windows[C] // Proceedings of the IEEE/CVF International Conference on Computer Vision, 2021 : 10012 – 10022.
- [31] ZHU X, LV S, WANG X, et al. TPH – YOLOv5: improved YOLOv5 based on transformer prediction head for object detection on drone-captured scenarios[C] // Proceedings of the IEEE/CVF International Conference on Computer Vision, 2021 : 2778 – 2788.
- [32] DENG J, DONG W, SOCHER R, et al. Imagenet: a large-scale hierarchical image database[C] // 2009 IEEE Conference on Computer Vision and Pattern Recognition. IEEE, 2009 : 248 – 255.
- [33] LOSHCHILOV I, HUTTER F. SGDR: stochastic gradient descent with warm restarts[J]. arXiv Preprint, arXiv:1608.03983, 2016.
- [34] BODLA N, SINGH B, CHELLAPPA R, et al. Soft-NMS—improving object detection with one line of code[C] // Proceedings of the IEEE International Conference on Computer Vision, 2017 : 5561 – 5569.