

基于 LMP SO – SVM 的高光谱水稻稻瘟病害分级检测

刘 潭^{1,2} 李子默¹ 冯 帅¹ 王雯琦¹ 袁青云¹ 许童羽^{1,2}

(1. 沈阳农业大学信息与电气工程学院, 沈阳 110866; 2. 辽宁省农业信息化工程技术研究中心, 沈阳 110866)

摘要: 为减少水稻产量损失,迫切需要建立快速、准确的水稻叶瘟监测和鉴别方法。本文以东北水稻为研究对象,以小区试验为基础,使用高光谱图像仪获取受稻瘟病菌侵染后不同发病程度的水稻叶片高光谱图像并提取光谱数据。首先,通过 SG 平滑方法对光谱数据进行预处理,然后运用主成分分析(PCA)、Pearson 相关系数分析法(PCCs)、PLS – VIP 方法对光谱数据进行降维,并提出了一种基于 Logistic 混沌映射 PSO 寻优的 SVM 分级检测模型(LMP SO – SVM)。为了验证提出方法的有效性,以不同降维方法提取的特征变量为输入,分别建立基于人工神经网络(ANN)、支持向量机(SVM)和 PSO – SVM 的分级模型并进行对比分析。仿真结果表明,各模型对 4 级病害的识别效果最好,综合 5 种级别病害,SVM 和 ANN 分级模型的预测准确率波动相对较大,对于病害预测效果不太理想;而在不同特征选择下建立的 LMP SO – SVM 分级模型对各级病害预测准确率均较高,准确率波动较小,其中基于 PCA 提取特征变量和全波段作为输入的模型平均准确率非常相近,分别为 96.49% 和 96.12%,PCA 提取的输入变量仅为 5 个,大大简化了模型复杂性,降低了训练难度和训练时间。综合分析,PCA – LMP SO – SVM 模型的训练效果最好,可以认为是最佳病害分级模型,其 5 种级别病害准确率分别为 94.29%、96.43%、93.44%、98.30% 和 100%。因此,本文提出的方法可进一步提高水稻稻瘟病分级检测精度和可靠性,结果可为确定稻瘟病发生情况提供一定的理论基础和技术支撑。

关键词: 水稻稻瘟病; 病害检测; 高光谱降维; 粒子群算法; LMP SO – SVM

中图分类号: S511; S41 – 30

文献标识码: A

文章编号: 1000-1298(2023)11-0208-09

OSID:



Classification Detection of Hyperspectral Rice Blast Disease
Based on LMP SO – SVM

LIU Tan^{1,2} LI Zimo¹ FENG Shuai¹ WANG Wenqi¹ YUAN Qingyun¹ XU Tongyu^{1,2}

(1. College of Information and Electrical Engineering, Shenyang Agricultural University, Shenyang 110866, China

2. Liaoning Engineering Technology Research Center of Agricultural Informatization, Shenyang 110866, China)

Abstract: Rice blast is one of the three major rice diseases in the world, which poses a serious threat to food security of China. In order to reduce yield loss, it is urgent to establish a rapid and accurate method for monitoring and identifying rice leaf blast. Rice in northeast China is taken as the research object. Based on a plot experiment, hyperspectral images of rice leaves with different degrees of disease after infection by rice blast fungus were obtained through hyperspectral image analyzer, and spectral data was extracted. Firstly, the SG smoothing method was used to preprocess the spectral data, and then principal component analysis (PCA), Pearson correlation coefficient analysis (PCCs), and PLS – VIP method were used to reduce the dimensionality of the spectral data. An SVM classification detection model based on Logistic chaotic mapping PSO optimization (LMP SO – SVM) was proposed. To verify the effectiveness of the proposed method, classification models based on artificial neural network (ANN), support vector machine (SVM) and particle swarm optimization – support vector machine (PSO – SVM) were established by using feature variables extracted by different dimensionality reduction methods, and were compared and analyzed. The simulation results showed that each model had the best detection

收稿日期: 2023 – 04 – 13 修回日期: 2023 – 07 – 18

基金项目: 辽宁省教育厅面上项目(LJKMZ20221035、LJKZ0683)、国家重点研发计划项目(2022YFD2002303 – 01)、辽宁省重点研发计划项目(2019JH2/10200002)和国家自然科学基金项目(320001415)

作者简介: 刘潭(1985 –),男,副教授,博士,主要从事智能优化算法和农业遥感研究,E-mail: liutan_0822@126.com

通信作者: 许童羽(1967 –),男,教授,主要从事农业航空领域研究,E-mail: xutongyu@syau.edu.cn

performance for level 4 samples. For these five levels of diseases, the prediction accuracy of SVM and ANN classification models fluctuated relatively large, and the effect of disease prediction was not ideal. The LMP SO - SVM classification model established under different feature selection had high accuracy for disease prediction at all levels, and the accuracy fluctuated less. The average accuracy of the model based on PCA extraction of feature variables and the whole band as input was very similar, with 96. 49% and 96. 12%, respectively. However, the number of input variables extracted by PCA was only 5, which greatly simplified the model complexity, reduced the difficulty and time of training. Comprehensive analysis showed that the PCA - LMP SO - SVM model had the best training effect and could be considered as the best disease classification model. The accuracy rates for the five levels of diseases were 94. 29%, 96. 43%, 93. 44%, 98. 30% and 100%, respectively. Therefore, the proposed method could further improve the accuracy and reliability of rice blast classification detection, and the results could provide a certain theoretical basis and technical support for the occurrence of rice blast diseases.

Key words: rice blast disease; disease detection; hyperspectral dimensionality reduction; particle swarm algorithm; LMP SO - SVM

0 引言

稻瘟病是水稻生产中主要病害之一,每年可造成产量 10% ~ 30% 的损失^[1],在我国平均每年发生稻瘟病的种植面积高达 3.8×10^6 hm²,年均损失约 20 万吨大米^[2]。稻瘟病造成的水稻产量下降对我国粮食安全造成了严重威胁^[3]。为了控制稻瘟病的大面积传播,减少产量损失,迫切需要建立快速、准确的相关病害监测和鉴别方法。

近年来,高光谱成像技术由于其光谱分辨率高、能提供图像和光谱信息的优点逐渐成为研究热点,被大量用于农作物病害检测^[4-6]。吴静珠等^[7]通过对比多种预处理方法对于不同噪声光谱数据的处理结果得出结论,在数据较差时,使用预处理方法将有效提升模型质量。第五鹏瑶等^[8]发现,对于不同的数据集,因为信息和复杂性不同,所以其最佳预处理方法也不同。对于相同数据集,即使光谱相同,各组分的预处理方法也存在差异。雷雨等^[9]通过对光谱数据进行主成分分析,得到了前 4 个主成分,其中 PC1 包含的信息最多,保留光谱的绝大部分信息,然而叶片健康区域的灰度较高,与病斑区域的灰度相近,导致与病斑区域界线比较模糊,不利于病斑提取,PC3 和 PC4 包含信息较少且噪声偏大,最后选择 PC2 作为主成分,模型准确率为 98. 15%。谢亚平等^[10]对多种农作物使用高光谱数据建模。NETTLETON 等^[11]证明了基于数据驱动模型可用于提供早期预警,预测稻瘟病。黄双萍等^[12]基于 GoogLeNet 方法对水稻高光谱图像构建模型,最高准确率为 92%;康丽等^[13]对水稻高光谱数据使用 CARS - PCA 提取特征波段,并采用支持向量机对数据进行建模,模型整体准确率达到 96. 61%。FENG 等^[14]基于特征融合使用一维卷积神经网络对水稻高光谱图像进行建模,整体准确率达到 98. 58%。

肖文等^[15]通过分窗 Gram - Schmidt 变换降维,有效地检测水稻纹枯病,且可以将其病情指数用于高光谱反演。HARAKANNANAVAR 等^[16]通过 SVM、CNN、KNN 3 种方法对番茄病害进行分级建模,最终准确率分别为 88%、96%、99. 6%。上述研究已对基于高光谱信息的水稻病害分级检测进行了一定研究,证明通过高光谱建立水稻稻瘟病分类模型是可行的,但是对于各种光谱特征提取分析及光谱分级模型的建立还需要进行深入研究。

本文利用室内高光谱成像系统获取水稻叶片高光谱图像,使用 SG 平滑方法对光谱数据进行预处理,然后采用主成分分析(PCA)、Pearson 相关系数分析法(PCCs)、PLS - VIP 方法分别对光谱数据进行降维,以不同方法提取的特征变量为输入,分别建立基于人工神经网络 ANN、支持向量机 SVM 和 PSO - SVM 的分级模型,同时提出基于 LMP SO - SVM 的预测模型并进行对比分析,以期的高光谱信息检测水稻稻瘟病病害提供研究思路和方法。

1 数据获取与处理

1. 1 水稻数据采样

水稻样本采集于辽宁省沈阳市沈北新区柳条河村,采集时间为 2020 年 7—8 月。试验品种为对稻瘟病高度敏感的蒙古稻,种植面积约 100 m²,行距 30 cm,株距 17 cm。氮肥、钾肥和磷肥的施用量分别为 45、15、51. 75 kg/hm²,符合当地标准。在水稻拔节期(7 月 8 日、7 月 15 日)、孕穗期(7 月 25 日、8 月 2 日)和抽穗期(8 月 10 日)这 3 个关键生育期进行了 5 次试验,以收集健康和患病植株。根据 GB/T 15790—2009《稻瘟病测报调查规范》,使用软件 ENVI 5. 3 计算患病区域和整片叶片的像素点的百分比,对采集的水稻样本稻瘟病病害等级进行判定。具体如表 1 所示。

表 1 光谱样本数量统计

Tab. 1 Statistics of number of spectral samples		
病害级别	病斑级别标准	样本数量
0	没有病斑	37
1	病斑面积占叶片面积小于 1%	54
2	病斑面积占叶片面积百分比为[1% ,5%)	59
3	病斑面积占叶片面积百分比为[5% ,10%)	58
4	病斑面积占叶片面积百分比为[10% ,50%)	48
总样本数量		256

本研究中,使用高光谱成像系统获取水稻叶片的高光谱图像,如图 1 所示。




图 1 高光谱成像系统

Fig. 1 Hyperspectral imaging system

1. CCD 摄像机 2. 高光谱仪 3. 镜头 4. 光源控制器 5. 光源
6. 移动台 7. 位移控制台 8. 计算机

该系统的主要部件包括 1 个高光谱成像光谱仪 (ImSpector V10E 型)、1 台高清摄像机 (IGV - B1410 型)、1 台精密位移控制台、1 个无光暗箱、2 盏 150 W 的光纤卤素灯 (美国海洋光学公司) 和 1 台计算机。该高光谱成像系统获得的有效光谱范围为 400 ~ 1 000 nm, 光谱分辨率为 1.09 nm。在获取图像之前,相机镜头与水稻叶片表面的距离设置为 32 cm。使用带有黑色条纹的白纸调焦板调整透镜焦距,直到黑色条纹成像,并且黑色条纹和白纸之间的过渡区域清晰。为了获得最佳图像质量,调整光源强度和曝光率,并将扫描速度设置为 1.1 mm/s。

由于叶片表面光强的变化和相机暗电流导致不同空间高光谱数据的强度不一致的问题,原始高光谱图像需要进行黑白板校正,以获得最终图像光谱反射率。校正公式为

$$I = \frac{R_s - R_D}{R_w - R_D} \tag{1}$$

式中 I ——水稻叶片校正高光谱反射率

R_s ——水稻叶片原始高光谱图像光谱反射率

R_w ——校正白板光谱反射率

R_D ——校正黑板光谱反射率

本研究将整片水稻叶片作为一个单独的感兴趣区域 (ROI),利用软件 ENVI 5.3 人工圈定感兴趣区

域并提取其平均光谱反射率。图 2 为水稻样本光谱曲线。




图 2 水稻样本光谱曲线

Fig. 2 Spectral curves of rice samples

1.2 光谱数据预处理

由于拍摄装置以及光照因素影响,高光谱数据存在噪声,需要对其进行预处理以降低噪声^[17]。本文使用 SG 平滑对光谱数据进行预处理。SG 平滑是由 SAVITZKY 和 GOLAY 提出的一种基于最小二乘法的平滑算法。把光谱区间的 c 个连续点作为一个窗口,用多项式对窗口内的光谱数据进行最小二乘拟合,确定多项式系数,然后计算窗口中心波长的 SG 平滑值,通过窗口移动得到原光谱的 SG 平滑谱^[18-19]。图 3 为 SG 平滑后的光谱曲线。




图 3 SG 平滑光谱曲线

Fig. 3 SG smoothing spectral curves

由光谱处理前后的对比结果可见,经 SG 平滑后光谱曲线变得更加平滑,去掉了部分冗余信息,且保持光谱整体形状几乎没有改变。

1.3 特征波长选取

由于高光谱数据维度高,信息相关性强,存在大量冗余信息,对模型精度有不利影响,使用原始光谱数据进行建模计算量大且容易产生过拟合,所以有必要对光谱进行降维。本文在光谱预处理基础上,分别选用主成分分析、Pearson 相关系数和变量投影重要性 (PLS - VIP) 方法对数据进行降维,提取光谱特征。

1.3.1 主成分分析方法

主成分分析 (Principal component analysis, PCA)

是通过正交变换的方法,将光谱信息投影到新的低维度坐标空间中。PCA 可在保留大部分光谱数据信息的前提下,降低光谱维度^[20]。具体步骤为:①对光谱数据进行归一化处理。②计算光谱数据的协方差矩阵。③求出矩阵的特征值和特征向量。④特征向量根据特征值,由大到小排列为一个 $n \times m$ 的矩阵,取前 k 列作为降维后的特征向量。⑤将数据转换到 k 个特征向量构建的新空间中,即 $Y = PX$;其中 P 为变换矩阵, X 为原始矩阵, Y 为变换后矩阵。

1.3.2 Pearson 相关系数分析

Pearson 相关系数 (Pearson correlation coefficient, PCCs) 是表述 2 组数据线性相关性的变量,相较于其他相关系数,如果不存在异常值, Pearson 相关系数更加稳定,且不受样本量的影响^[21]。

$$r = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} \quad (2)$$

式中 $\bar{x}$ —— x 的算术平均值
 $\bar{y}$ —— y 的算术平均值
 r ——Pearson 相关系数 n ——样本量

r 位于 -1 到 1 之间,越接近 1 ,相关性越大。通常情况下, r 为正值表示两者相关方向为正相关,负值表示相关方向为负相关;当 $|r| = 1$,两者线性相关; $0.8 \leq |r| < 1$,两者极强相关; $0.6 \leq |r| < 0.8$,两者高度相关; $0.4 \leq |r| < 0.6$,两者中度相关; $|r| < 0.4$,两者低度相关; $|r| = 0$,两者没有线性关系。

1.3.3 变量投影重要性

变量投影重要性指标是一种基于 PLS 的变量筛选方法,是建立在自变量与因变量矩阵基础上的降维方法,表示自变量 x_j 在解释因变量 Y 时作用的重要性。其广泛应用于多重共线性、样本相对自变量较小的情况。变量投影重要性指标计算公式为

$$VIP_j = \sqrt{p \sum_{h=1}^{m_0} R(Y, t_h) w_{hj}^2 / \sum_{h=1}^{m_0} R(Y, t_h)} \quad (3)$$

式中 p ——自变量个数
 m_0 ——PLS 成分数
 t_h ——第 h 个成分
 $R(Y, t_h)$ ——成分 t_h 对因变量 Y 的解释能力,为二者相关系数的平方
 w_{hj} ——轴 w_h 的第 j 个分量

VIP 值越大,说明该自变量对于因变量的贡献率越大^[22]。当 VIP 值大于 1 时,说明该自变量对因变量的贡献较大,当 VIP 小于 0.8 时说明该自变量

对因变量贡献较小。

1.4 分类模型构建

1.4.1 人工神经网络

人工神经网络 (Artificial neural network, ANN) 是一种模仿人体大脑神经的运算模型,通过神经元相互连接组成。人工神经网络包括输入层、隐藏层和输出层,通过隐藏层的非线性变换,可以拟合任意非线性函数。由于数据量偏小,属于小样本训练,容易产生过拟合。引用 dropout 层方法,可以防止模型过拟合,有效提高模型的泛化能力,dropout 层通常在全连接层之后,每次训练时随机舍弃部分神经元,减少参数数量,增加特征之间的正交性。

1.4.2 支持向量机 SVM

支持向量机 (Support vector machine, SVM) 是一种常用的监督学习方法,它可以有效解决线性二分类问题,通过引入核函数 (kernel) 的支持向量机,将向量投影到更高维空间,其中样本向量是线性可分的,并在这个新模型中估计最大边缘超平面空间,以提高数据的线性可分性^[23]。可以通过 OVR 策略,实现支持向量机对样本多分类^[24]。

SVM 引入核函数可以有效解决非线性问题,但是核函数系数对于 SVM 分类效果影响明显,核函数系数和惩罚因子的选择十分重要,传统方法通常采用网格搜索法对 SVM 进行参数寻优,将待搜索参数在坐标系中分成尺寸相同的网格,其中每个网格的点代表一个参数,将参数代入 SVM 中获得当前参数对应的准确率,通常情况下网格越小,搜索区域越大,算法准确率越高,但是这种方法的大部分参数所对应的准确率都很低,会获得大量无用信息,且会随寻优参数数量的增加,算法的运算数量呈指数级增长,严重浪费收敛时间^[25]。

1.4.3 PSO - SVM 模型

粒子群优化 (Partricle swarm optimization, PSO) 是一种模拟鸟类捕食的优化算法,将每只鸟视为一个粒子,每个粒子会不断向自身历史最佳位置 pbest 和粒子群历史最佳位置 gbest 移动,以寻找最优解。目前已经广泛运用于机器学习参数寻优方面^[26]。具体步骤如下:①初始化粒子群。②计算每个粒子的适应度。③对每个粒子使用当前个体适应度和个体历史最佳适应度作比较。④对每个粒子使用当前个体适应度和全局历史最佳适应度作比较。⑤更新粒子速度和位置。⑥判断是否满足算法终止条件,如果符合,结束算法并输出最优结果;否则返回步骤②。

1.4.4 基于 LMP SO 寻优的 SVM 模型

基于 PSO 寻优的 SVM,可以有效解决网格搜索

法效率低的问题,但是 PSO 算法的每个粒子依赖惯性因子来改变粒子位置,惯性因子过大会导致粒子发散而不能找到最佳位置,过小会导致粒子陷入局部最优解^[27-28]。在标准 PSO 优化算法基础上,提出一种基于 LMPSO 改进寻优 SVM 的稻瘟病分级模型(LMPSO-SVM)。

在算法初期,更关注算法的全局搜索能力,因此惯性因子应该较大,以实现粒子快速寻优。在算法后期更关注局部寻优能力,因此惯性因子应该较小,以实现粒子准确寻找全局最优点。线性递减惯性因子可以有效平衡全局搜索和局部搜索,即

$$w(d) = w_s - \frac{(w_s - w_e)d}{K}$$

(4)

式中 d ——当前迭代次数
 K ——最大迭代次数
 $w(d)$ ——当前迭代次数的惯性因子
 w_s ——惯性因子最小值
 w_e ——惯性因子最大值

当随机粒子分布不合理时,粒子群算法会过早收敛,从而进入局部最优解,随着线性递减惯性因子逐渐减小,算法后期会更加难以跳出局部最优点,本文引入 Logistic 混沌映射^[29],其公式为

$$x_{k+1} = ax_k(1 - x_k) \quad (a \in [0, 4], x_k \in (0, 1))$$

(5)

式中 a ——分支参数
 x_k ——待映射粒子
 x_{k+1} ——映射后粒子

当 $a = 4$ 时,获得的粒子将处于混沌状态。Logistic 映射可以帮助粒子群增加搜索能力^[30-31],首先,使用式(5)对粒子位置进行初始化,以优化初始粒子分布,有利于提高初始解的质量^[32],当粒子群算法后期最佳适应度不再变化时,以历史最佳位置为中心按照一定的范围使用 Logistic 映射,将获得新的位置替换历史最佳位置,在陷入局部最优位置时,可有效跳出局部最优解,LMPSO-SVM 算法流程如图 4 所示。

2 结果和分析

2.1 不同病害等级光谱反射率分析

为分析不同病害等级对水稻光谱反射率影响,本研究绘制水稻样本平均光谱曲线,如图 5 所示。

由图 5 可以看出,在绿光区、红光区的水稻冠层光谱反射率随病情程度的加重呈现下降趋势;绿光吸收边缘的特征波长发生红移,红光吸收边缘和近红外吸收边缘的特征波长发生蓝移。受害较轻时近红外区反射率变化幅度大,受害重时绿光区和红光




图 4 LMPSO-SVM 算法流程图

Fig. 4 LMPSO-SVM algorithm flowchart




图 5 5 种病害等级平均光谱曲线

Fig. 5 Average spectral curves of five disease grades

区反射率变化幅度大^[33]。在光谱绿光和红光区域,光谱曲线随着病害加重,光谱反射率逐渐下降。

2.2 特征波段提取结果

2.2.1 基于 PCA 的光谱特征提取

使用主成分分析,将全波段(551 个波段)转换为几个主成分,选取方差累计贡献率最高的 5 个主成分,各主成分的方差贡献率以及累计方差贡献率如表 2 所示,累计贡献率为 99.85%,覆盖了光谱的绝大部分信息。

表 2 光谱数据各主成分方差贡献率和累计贡献率

Tab. 2 Variance contribution and cumulative contribution of each principal component of spectral data %

主成分	方差贡献率	累计贡献率
PC1	87.47	87.47
PC2	11.00	98.47
PC3	0.93	99.40
PC4	0.34	99.74
PC5	0.11	99.85

2.2.2 基于 Pearson 相关系数法的特征提取

使用 Pearson 相关系数法对数据进行特征选择,图 6 为光谱特征相关系数。




图 6 光谱特征相关系数

Fig.6 Correlation coefficient of spectral features

如图 6 所示,大部分波段相关系数较低,少数波段呈高相关性,将 $r > 0.7$ 的波段视为特征波段,其特征波段全部分布在 585 ~ 667 nm 之间,共计 78 个。

2.2.3 基于 PLS - VIP 的光谱特征提取

使用 PLS - VIP 对数据进行特征选择,图 7 为 PLS - VIP 的贡献率。




图 7 光谱数据 PLS - VIP 贡献率

Fig.7 PLS - VIP contribution rate of spectral data

由图 7 可见,大部分波段贡献率均低于 1,少数波段有较高贡献率,将 VIP 值大于 1.5 的波段视为特征波段,其中特征波段主要分布在 560 ~ 631 nm 和 682 ~ 689 nm 区间,共计 100 个特征波段。

2.3 分类建模精度比较

训练前将光谱波段数据随机打乱,将数据集以比例 8 : 2 分为训练集和测试集,使用准确率 (Precision) 对模型进行评估。

本文使用 LMPSO - SVM 算法对光谱数据进行建模并分别与 SVM、ANN 和 PSO - SVM 模型进行对比。标准 SVM 使用网格搜索法对模型进行参数寻优,人工神经网络的隐含层激活函数为 ReLU 函数,优化器算法为 Adam 优化算法,学习率为 0.001, batch size 设置为 8。LMPSO - SVM 模型粒子群数量为 50,迭代 500 次,全局学习因子为 2,局部学习因

子为 2,初始惯性因子为 0.8,终止惯性因子为 0.4,参数最大值为 10 000,最小值为 0.001。表 3、4 分别为 PSO 和 LMPSO 算法对 SVM 的参数寻优结果,其中 Gamma 为核函数系数, C 为惩罚因子。

表 3 PSO 寻优 SVM 参数
Tab.3 SVM parameters optimized by PSO

特征波段	Gamma	C
全波段	1.934 8	3 318.720 5
PCA	12.190 9	56.656 6
PLS - VIP	8.501 9	8 562.679 8
PCCs	144.513 3	451.817 0

表 4 LMPSO 寻优 SVM 参数

Tab.4 SVM parameters optimized by LMPSO

特征波段	Gamma	C
全波段	0.246 8	3 590.758 2
PCA	0.323 7	7 044.685 0
PLS - VIP	26.267 2	1 692.811 6
PCCs	27.571 1	4 372.204 4

如果粒子间方差过小,通常认为此时的最佳位置为局部最优位置,使用 Logistic 映射规则将目前全局最优位置映射到新的位置,从而跳出局部最优位置。图 8 显示了全波段输入时,基于 LMPSO 算法寻优 SVM 参数随着迭代次数的适应度变化曲线和平均适应度曲线。




图 8 LMPSO 算法寻优 SVM 参数时随着迭代次数的适应度变化曲线

Fig.8 Fitness curves with iteration number when LMPSO algorithm optimized SVM parameters

从图 8 可以看出,LMPSO 算法不仅保持了较快的收敛速度,而且算法使用混沌映射对全局最优位置进行映射,可多次跳出局部最优解,取得了较好的参数寻优效果。

表 5 列出了各分级模型预测准确率,可以看出,所有模型的样本总体检测精度较高。各模型对 4 级病害的检测准确率最高,0 级病害和 4 级病害相当,识别效果较好;对 1 级和 2 级病害的检测准确率最高为 98.15% 和 95.08%,最低为 73.21% 和

76.06%。在 ANN 模型下,PLS - VIP 建模的准确率最高,平均为 93.34%,其中 0 级、3 级和 4 级病害预测准确率均为 100%,2 级病害预测准确率最低仅为 79.41%。在 SVM 模型下,PCA 建模显示了较高的准确率,平均为 96.26%,其中 0 级和 4 级病害预测准确率最高为 100%,1 级病害预测准确率最低为 91.07%。在 PSO - SVM 模型下,全波段建模的准确率最高,平均为 95.74%,其中 0 级和 4 级病害预测准确率最高均为 100%,2 级病害预测准确率最低为

92.06%。在 LMPSO - SVM 模型下,PCA 提取 5 个特征变量建立的模型,平均准确率为 96.49%,在大幅减少模型输入变量的同时获得了良好的预测效果,且各级病害准确率均较高,其中对 4 级病害预测准确率最高为 100%,对 2 级病害预测准确率最低为 93.44%。因此,基于 PCA 提取特征变量建立的 LMPSO - SVM 分级模型可以在提高预测精确性和稳定性同时大大简化模型复杂性,进一步提高模型整体性能。

表 5 模型预测准确率							
Tab.5 Model prediction precision							%
建模方法	特征波段	0 级病害	1 级病害	2 级病害	3 级病害	4 级病害	平均值
SVM	全波段	100	98.15	95.08	98.31	88.24	95.96
	PCA	100	91.07	91.94	98.31	100	96.26
	PCCs	93.33	83.87	87.30	96.61	97.62	91.75
	PLS - VIP	100	91.07	89.06	95.08	100	95.04
ANN	全波段	96.97	80.00	94.23	96.67	97.83	93.14
	PCA	93.55	87.04	88.06	95.08	100	92.75
	PCCs	100	73.21	76.06	90.63	100	87.98
	PLS - VIP	100	87.27	79.41	100	100	93.34
PSO - SVM	全波段	100	93.10	92.06	93.55	100	95.74
	PCA	94.29	92.98	91.94	96.67	95.65	94.31
	PCCs	90.32	86.44	88.71	96.67	97.67	91.96
	PLS - VIP	96.77	96.30	93.44	95.81	100	94.99
LMPSO - SVM	全波段	94.44	94.64	94.92	96.67	100	96.12
	PCA	94.29	96.43	93.44	98.30	100	96.49
	PCCs	91.67	89.47	90.00	93.55	100	92.94
	PLS - VIP	94.29	91.23	93.33	96.67	100	95.10

从整体建模角度来看,分别对比 SVM、ANN、PSO - SVM 和 LMPSO - SVM 4 种模型对不同特征建模的预测准确率,可以看出本文提出的 LMPSO - SVM 分级模型的平均准确率均高于其他模型。为进一步分析,分别以全波段和 PCA、PCCs、PLS - VIP 方法提取的特征变量为输入建立 LMPSO - SVM 模型混淆矩阵,如图 9 所示。其中对角线为正确分类的数据,全波段共有 10 处错误分类,PCA 共有 9 处错误分类,PCCs 共有 19 处错误分类,PLS - VIP 共有 13 处错误分类,对比 4 个混淆矩阵,可以看出全波段与 PCA 为输入的模型准确率较高,误分对象主要集中在相邻病害之间,可能是由于相邻的病害特征相似所导致,但在大部分水稻叶片光谱特征分类上均保持了较高的准确率。

3 讨论

以东北水稻为研究对象,利用高光谱技术对水稻稻瘟病病害进行分级检测,分别采用高光谱数据全波段、主成分分析(PCA)、Pearson 相关系数分析




图 9 LMPSO - SVM 模型混淆矩阵

Fig.9 Confusion matrix of LMPSO - SVM model

法(PCCs)、PLS - VIP 降维方法对光谱数据进行降维,并提出了一种基于 LMPSO - SVM 的分级建模方法对提取的光谱特征进行建模。

可以发现,采用不同特征提取方法建立的 SVM、ANN、PSO - SVM、LMP SO - SVM 4 种分级模型中,LMP SO - SVM 模型的平均准确率更高。在所有 SVM 模型中,最低病害级别的准确率均较低,如全波段模型下 4 级病害预测准确率只有 88.24%,不足以有效准确预测病害级别;在 ANN 模型中,综合 5 种级别病害,模型预测准确率波动较大,平均准确率较低,对于病害预测效果不好。相对网格搜索法的标准 SVM 分级模型,PSO - SVM 模型的训练速度较为明显提升,显示了一定优势,但 PSO - SVM 模型的部分平均准确率略低于网格搜索法,原因可能是存在局部最优位置,一定程度上降低了模型精度,而本文提出的 LMP SO - SVM 分级模型,在 PSO - SVM 方法基础上,采用线性递减惯性因子可以有效平衡全局搜索和局部搜索,同时融入 Logistic 映射算法增加粒子群搜索能力,进一步提高 PSO 的全局寻优能力。因此,构建的 LMP SO - SVM 模型在不同特征选择下各级病害预测准确率均较高,准确率波动较小,且算法平均准确率及训练时间均优于网格搜索法,其中全波段和 PCA 数据下的模型平均准确率相近,分别为 96.12% 和 96.49%,PCA 维度为 5,其中全波段建模训练时间为 1 392 s,PCA 特征波段建模训练时间为 709 s,大幅降低了训练难度和训练时间,并且拥有较高的准确率。综合来看,PCA - LMP SO - SVM 模型的训练效果最好,可认为是最佳训练模型,其 5 种级别病害准确率分别为 94.29%、96.43%、93.44%、98.30%、100%。

本研究中对水稻稻瘟病害分级检测时,目前采用近 1 ~ 2 年数据来构建水稻病害分级检测模型,但可为下一步开展长时间序列的水稻稻瘟病害分级检测奠定良好基础。此外,诸如水稻等作物病害分级检测目前还没有统一的标准模型,虽然本文构建了水稻在一些关键生育期内的整体模型,但最佳的分级模型也会因各生育期、水稻品种等条件不同而存在一定差异,未来仍需广泛采集样本,进一步完善模型,以便更好地推广应用,得到更具普适性的水稻病害精确分级检测模型。

4 结束语

利用室内高光谱成像系统获取水稻叶片高光谱图像,对光谱数据使用 SG 平滑进行预处理,分别采用 PCA、Pearson 相关系数和 PLS - VIP 方法提取光谱特征,同时提出了一种基于 LMP SO - SVM 的水稻稻瘟病分级模型,并分别与 SVM、ANN 和 PSO - SVM 模型进行对比分析。结果表明:基于 LMP SO - SVM 的分级模型具有更高的全局搜索能力,相较于 SVM 和 ANN 模型的分级预测波动较小,平均准确率更高。其中,基于 PCA 方法提取光谱特征作为输入建立的 LMP SO - SVM 模型 (PCA - LMP SO - SVM) 具有更高的平均预测精度,且 PCA 方法提取光谱特征维度更低,大大简化了模型的复杂性。因此,本文提出的方法可为基于高光谱信息的水稻稻瘟病害分级模型建立提供新的研究思路和方法,为水稻等作物病害分级检测提供了一定理论依据。

参 考 文 献

[1] NEUPANE N, BHUSAL K. A review of blast disease of rice in Nepal[J]. Journal of Plant Pathology & Microbiology, 2021, 11: 528.

[2] FENG S, ZHAO D, GUAN Q, et al. A deep convolutional neural network-based wavelength selection method for spectral characteristics of rice blast disease[J]. Computers and Electronics in Agriculture, 2022, 199: 107199.

[3] ASIBI A E, CHAI Q, COULTER J A. Rice blast: a disease with implications for global food security[J]. Agronomy, 2019, 9(8): 451 - 455.

[4] 曹益飞, 徐焕良, 吴玉强, 等. 基于时序高光谱和多任务学习的水稻病害早期预测研究[J]. 农业机械学报, 2022, 53(11): 288 - 298.

CAO Yifei, XU Huanliang, WU Yuqiang, et al. Early forecasting of rice disease based on time series hyperspectral imaging and multi-task learning[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(11): 288 - 298. (in Chinese)

[5] ALMOUJAHED M B, RANGARAJAN A K, WHETTON R L, et al. Detection of fusarium head blight in wheat under field conditions using a hyperspectral camera and machine learning[J]. Computers and Electronics in Agriculture, 2022, 203: 107456.

[6] RANGARAJAN A K, WHETTON R L, MOUAZEN A M. Detection of fusarium head blight in wheat using hyperspectral data and deep learning[J]. Expert Systems with Applications, 2022, 208: 118240.

[7] 吴静珠, 李慧, 王克栋, 等. 光谱预处理在农产品近红外模型优化中的应用研究[J]. 农机化研究, 2011, 33(3): 178 - 181.

WU Jingzhu, LI Hui, WANG Kedong, et al. Application of spectrum preprocessing algorithms in optimizing NIR models of agricultural products[J]. Journal of Agricultural Mechanization Research, 2011, 33(3): 178 - 181. (in Chinese)

[8] 第五鹏瑶, 卞希慧, 王姿方, 等. 光谱预处理方法选择研究[J]. 光谱学与光谱分析, 2019, 39(9): 2800 - 2806.

DIWU Pengyao, BIAN Xihui, WANG Zifang, et al. Study on the selection of spectral preprocessing methods[J]. Spectroscopy and Spectral Analysis, 2019, 39(9): 2800 - 2806. (in Chinese)

- [9] 雷雨,韩德俊,曾庆东,等. 基于高光谱成像技术的小麦条锈病病害程度分级方法[J]. 农业机械学报, 2018, 49(5): 226 – 232.
LEI Yu, HAN Dejun, ZENG Qingdong, et al. Grading method of disease severity of wheat stripe rust based on hyperspectral imaging technology[J]. Transactions of the Chinese Society for Agricultural Machinery, 2018, 49(5): 226 – 232. (in Chinese)
- [10] 谢亚平,陈丰农,张竞成,等. 基于高光谱技术的农作物常见病害监测研究[J]. 光谱学与光谱分析, 2018, 38(7): 2233 – 2240.
XIE Yaping, CHEN Fengnong, ZHANG Jingcheng, et al. Study on monitoring of common diseases of crops based on hyperspectral technology[J]. Spectroscopy and Spectral Analysis, 2018, 38(7): 2233 – 2240. (in Chinese)
- [11] 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.
- [12] 黄双萍,孙超,齐龙,等. 基于深度卷积神经网络的水稻穗瘟病检测方法[J]. 农业工程学报, 2017, 33(20): 169 – 176.
HUANG Shuangping, SUN Chao, QI Long, et al. Rice panicle blast identification method based on deep convolution neural network[J]. Transactions of the CSAE, 2017, 33(20): 169 – 176. (in Chinese)
- [13] 康丽,袁建清,高睿,等. 高光谱成像的水稻稻瘟病早期分级检测[J]. 光谱学与光谱分析, 2021, 41(3): 898 – 902.
KANG Li, YUAN Jianqing, GAO Rui, et al. Early detection and identification of rich blast based on hyperspectral image[J]. Spectroscopy and Spectral Analysis, 2021, 41(3): 898 – 902. (in Chinese)
- [14] FENG S, CAO Y, XU T, et al. Rice leaf blast classification method based on fused features and one-dimensional deep convolutional neural network[J]. Remote Sensing, 2021, 13(16): 3207.
- [15] 肖文,曹英丽,冯帅,等. 基于分窗 Gram – Schmidt 变换和 PSO – SVR 算法的水稻纹枯病病情指数检测[J]. 光谱学与光谱分析, 2021, 41(7): 2181 – 2187.
XIAO Wen, CAO Yingli, FENG Shuai, et al. Detection of rich sheath blight disease index based on split-window Gram – Schmidt transformation and PSO – SVR algorithm[J]. Spectroscopy and Spectral Analysis, 2021, 41(7): 2181 – 2187. (in Chinese)
- [16] HARAKANNANAVAR S S, RUDAGI J M, PURANIKMATH V I, et al. Plant leaf disease detection using computer vision and machine learning algorithms[J]. Global Transitions Proceedings, 2022, 3(1): 305 – 310.
- [17] 李士静,潘羲,陈熙卓,等. 基于高光谱信息的烟叶分级方法比较[J]. 烟草科技, 2021, 54(10): 82 – 91.
LI Shijing, PAN Xi, CHEN Xizhuo, et al. Comparison of tobacco grading methods based on hyperspectral information[J]. Tobacco Science & Technology, 2021, 54(10): 82 – 91. (in Chinese)
- [18] 刘桂松,郭昊淞,潘涛,等. Vis – NIR 光谱模式识别结合 SG 平滑用于转基因甘蔗育种筛查[J]. 光谱学与光谱分析, 2014, 34(10): 2701 – 2706.
LIU Guisong, GUO Haosong, PAN Tao, et al. Vis – NIR spectroscopic pattern recognition combined with SG smoothing applied to breed screening of transgenic sugarcane[J]. Spectroscopy and Spectral Analysis, 2014, 34(10): 2701 – 2706. (in Chinese)
- [19] 季江,高鹏飞,贾南南,等. 自适应多尺度窗口平均光谱平滑[J]. 光谱学与光谱分析, 2015, 35(5): 1445 – 1449.
JI Jiang, GAO Pengfei, JIA Nannan, et al. Spectral smoothing with adaptive multiscale window average[J]. Spectroscopy and Spectral Analysis, 2015, 35(5): 1445 – 1449. (in Chinese)
- [20] HSIEH T H, KIANG J F. Comparison of CNN algorithms on hyperspectral image classification in agricultural lands[J]. Sensors, 2020, 20(6): 1734 – 1751.
- [21] TEMIZHAN E, MIRTAGIOGLU H, MENDES M. Which correlation coefficient should be used for investigating relations between quantitative variables[J]. Acad. Sci. Res. J. Eng. Technol. Sci., 2022, 85: 265 – 277.
- [22] ZHOU Q, YU L, ZHANG X, et al. Fusion of UAV hyperspectral imaging and LiDAR for the early detection of EAB stress in ash and a new EAB detection index-NDVI (776,678)[J]. Remote Sens., 2022, 14: 2428.
- [23] ZHANG Haibin, JI Xiaoping, WU Boying, et al. Fast elliptic curve point multiplication algorithm optimization[J]. Applied Mechanics and Materials, 2014, 441: 1044 – 1048.
- [24] 刘志刚,李德仁,秦前清,等. 支持向量机在多类分类问题中的推广[J]. 计算机工程与应用, 2004, 40(7): 10 – 13.
LIU Zhigang, LI Deren, QIN Qianqing, et al. An analytical overview of methods for multi-category support vector machines[J]. Computer Engineering and Applications, 2004, 40(7): 10 – 13. (in Chinese)
- [25] 刘小生,章治邦. 基于改进网格搜索法的 SVM 参数优化[J]. 江西理工大学学报, 2019, 40(1): 5 – 9.
LIU Xiaosheng, ZHANG Zhibang. Parameter optimization of support vector machine based on improved grid search method[J]. Journal of Jiangxi University of Science and Technology, 2019, 40(1): 5 – 9. (in Chinese)
- [26] 姜明辉,袁绪川,冯玉强. PSO – SVM 模型的构建与应用[J]. 哈尔滨工业大学学报, 2009, 41(2): 169 – 171.
JIANG Minghui, YUAN Xuchuan, FENG Yuqiang. Construction and application of PSO – SVM model[J]. Journal of Harbin Institute of Technology, 2009, 41(2): 169 – 171. (in Chinese)
- [27] 寇斌,郭士杰,任东城. 改进粒子群算法的工业机器人几何参数标定[J]. 哈尔滨工业大学学报, 2022, 54(1): 9 – 13.
KOU Bin, GUO Shijie, REN Dongcheng. Geometric parameter calibration of industrial robot based on improved particle swarm optimization[J]. Journal of Harbin Institute of Technology, 2022, 54(1): 9 – 13. (in Chinese)

- imaging technology[J]. Transactions of the Chinese Society for Agricultural Machinery, 2018, 49(5): 226 – 232. (in Chinese)
- [10] WSPANIALY P, MOUSSA M. A detection and severity estimation system for generic diseases of tomato greenhouse plants[J]. Computers and Electronics in Agriculture, 2020, 178: 105701.
- [11] GONÇALVES J P, PINTO F A C, QUEIROZ D M, et al. Deep learning architectures for semantic segmentation and automatic estimation of severity of foliar symptoms caused by diseases or pests[J]. Biosystems Engineering, 2021, 210: 129 – 142.
- [12] WANG C, DU P, WU H, et al. A cucumber leaf disease severity classification method based on the fusion of DeepLabV3 + and U – Net[J]. Computers and Electronics in Agriculture, 2021, 189: 106373.
- [13] 刘斌, 徐皓玮, 李承泽, 等. 基于快照集成卷积神经网络的苹果叶部病害程度识别[J]. 农业机械学报, 2022, 53(6): 286 – 294.
- LIU Bin, XU Haowei, LI Chengze, et al. Apple leaf disease identification method based on snapshot ensemble CNN[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(6): 286 – 294. (in Chinese)
- [14] RONNEBERGER O, FISCHER P, BROX T. U – Net: convolutional networks for biomedical image segmentation[C] // Proceedings of the Medical Image Computing and Computer-Assisted Intervention, 2015.
- [15] BADRINARAYANAN V, KENDALL A, CIPOLLA R. SegNet: a deep convolutional encoder-decoder architecture for image segmentation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(12): 2481 – 2495.
- [16] ZHAO H, SHI J, QI X, et al. Pyramid scene parsing network[C] // Proceedings of the 2017 IEEE Conference on Computer Vision and Pattern Recognition, 2017: 6230 – 6239.
- [17] LIN T, DOLLAR P, GIRSHICK R, et al. Feature pyramid networks for object detection[C] // Proceedings of the 2017 IEEE Conference on Computer Vision and Pattern Recognition, 2017: 936 – 944.
- [18] CHEN L C, ZHU Y, PAPANDREOU G, et al. Encoder-decoder with atrous separable convolution for semantic image segmentation[C] // Proceedings of the Computer Vision, 2018: 833 – 851.
- [19] YU C, WANG J, PENG C, et al. BiSeNet: bilateral segmentation network for real-time semantic segmentation[C] // Proceedings of the Computer Vision, 2018: 334 – 349.
- [20] YU C, GAO C, WANG J, et al. BiSeNet V2: bilateral network with guided aggregation for real-time semantic segmentation[J]. International Journal of Computer Vision, 2021, 129(11): 3051 – 3068.
- [21] FAN M, LAI S, HUANG J, et al. Rethinking BiSeNet for real-time semantic segmentation[C] // Proceedings of the 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 9716 – 9725.
- [22] PENG J, LIU Y, TANG S, et al. PP-LiteSeg: a superior real-time semantic segmentation model[J]. ArXiv:2204.02681, 2022.
- [23] PAN H, HONG Y, SUN W, et al. Deep dual-resolution networks for real-time and accurate semantic segmentation of traffic scenes[J]. IEEE Transactions on Intelligent Transportation Systems, 2023, 24(3): 3448 – 3460.
- [24] HUANG S, LU Z, CHENG R, et al. FaPN: feature-aligned pyramid network for dense image prediction[C] // Proceedings of the 2021 IEEE/CVF International Conference on Computer Vision, 2021: 844 – 853.
- [25] TAKIKAWA T, ACUNA D, JAMPANI V, et al. Gated-SCNN: gated shape CNNs for semantic segmentation[C] // Proceedings of the 2019 IEEE/CVF International Conference on Computer Vision, 2019: 5228 – 5237.
- [26] DENG J, DONG W, SOCHER R, et al. ImageNet: a large-scale hierarchical image database[C] // Proceedings of the 2009 IEEE Conference on Computer Vision and Pattern Recognition, 2009: 248 – 255.
-

(上接第 216 页)

- [28] HUANG L, WU K, HUANG W, et al. Detection of fusarium head blight in wheat ears using continuous wavelet analysis and PSO – SVM[J]. Agriculture, 2021, 11(10): 998.
- [29] 范九伦, 张雪锋. 分段 Logistic 混沌映射及其性能分析[J]. 电子学报, 2009, 37(4): 720 – 725.
- FAN Jiulun, ZHANG Xuefeng. Piecewise Logistic chaotic map and its performance analysis[J]. Acta Electronica Sinica, 2009, 37(4): 720 – 725. (in Chinese)
- [30] TAVAZOEI M S, HAERI M. An optimization algorithm based on chaotic behavior and fractal nature[J]. Journal of Computational and Applied Mathematics, 2007, 206(2): 1070 – 1081.
- [31] ZHAO C, ZHAO H, WANG G, et al. Improvement SVM classification performance of hyperspectral image using chaotic sequences in artificial bee colony[J]. IEEE Access, 2020, 8: 73947 – 73956.
- [32] ZHANG C, DING S. A stochastic configuration network based on chaotic sparrow search algorithm[J]. Knowledge-Based Systems, 2021, 220: 106924.
- [33] 吴曙雯, 王人潮, 陈晓斌, 等. 稻叶瘟对水稻光谱特性的影响研究[J]. 上海交通大学学报(农业科学版), 2002, 20(1): 73 – 76.
- WU Shuwen, WANG Renchao, CHEN Xiaobin, et al. Effects of rice leaf blast on spectrum reflectance of rice[J]. Journal of Shanghai Jiaotong University (Agricultural Science), 2002, 20(1): 73 – 76. (in Chinese)