

doi:10.6041/j.issn.1000-1298.2019.03.020

基于高光谱和深度迁移学习的柑橘叶片钾含量反演

岳学军 凌康杰 王林惠 岑振钊 卢杨 刘永鑫

(华南农业大学电子工程学院, 广州 510642)

摘要: 针对传统柑橘叶片钾含量检测方法耗时费力、操作繁琐且损伤叶片等弊端,引入高光谱信息探索柑橘叶片钾含量快速无损检测与预测模型,选用 ASD FieldSpec 3 光谱仪采集柑橘 4 个重要物候期(萌芽期、稳果期、壮果促梢期和采果期)的叶片反射光谱,同步采用火焰光度法测定叶片的钾含量;先用正交试验确定小波去噪的最佳去噪参数组合,再进行不同光谱形式变换,对不同物候期光谱进行基于堆栈稀疏编码器-深度学习网络(Stacked sparse autoencoder-deep learning networks,SSAE-DLNs)的特征提取迁移和融合多种特征,对比支持向量机回归、偏最小二乘法回归、广义神经网络、逐步多元线性回归等多种诊断模型,结果表明,模型 SSAE-DLNs 基于一阶微分光谱特征建立全生长期钾含量预测模型的性能最优,其校正集和验证集决定系数分别为 0.898 8、0.877 1,均方根误差分别为 0.544 3、0.552 8。试验表明,深度迁移学习网络可对柑橘叶片钾含量进行精确预测,为高光谱检测技术用于柑橘树长势监测和营养诊断提供了参考。

关键词: 柑橘叶片; 钾含量; 深度迁移学习; 堆栈稀疏自动编码器; 高光谱; 支持向量回归

中图分类号: S126 **文献标识码:** A **文章编号:** 1000-1298(2019)03-0186-10

Inversion of Potassium Content for Citrus Leaves Based on Hyperspectral and Deep Transfer Learning

YUE Xuejun LING Kangjie WANG Linhui CEN Zhenzhao LU Yang LIU Yongxin
(College of Electronic Engineering, South China Agricultural University, Guangzhou 510642, China)

Abstract: Traditional methods of obtaining potassium content of citrus leaves are time-consuming procedures with complex operations which can be harmful to citrus trees. Moreover, traditional methods cannot meet the demand for rapid and non-destructive monitoring of potassium content in large-scale citrus orchards. Combined with the state-of-the-art deep learning technology, a model based on stacked sparse autoencoder (SSAE) and deep learning networks (DLNs) using hyperspectral information for potassium content prediction in four growth stages was proposed. The experiments were conducted in the Crab Village of Luogang District, Guangzhou City, Guangdong Province, and the samples were 109 citrus trees planted. During four growth stages, i. e., germination, stability, bloom and picking stages, hyperspectral reflectance of citrus leaves was respectively measured by spectrometer (ASD FieldSpec 3), and at the same time, potassium content of citrus leaves was obtained by using traditional chemical method. All the collected samples constituted a large-scale dataset with totally 436 tuples, 80% of which were utilized as the calibration set and remaining 20% as the validation set. The constructed model which relied on the calibration set and the validation set was evaluated respectively. Firstly, successive projection algorithm (SPA) was provided to deal with the high-dimensional spectral vectors for dimension reduction and feature extraction. A prediction model of multiple linear regression (MLR) for potassium content of citrus leaves was established based on those extracted features. The result showed that the potassium spectrum contained a large number of complex nonlinear characteristics. Secondly, wavelet de-noising was applied to reduce the high-frequency noise in the original spectrum, and the optimized parameter combination of wavelet de-noising through orthogonal test was as follows: “coif2” as wavelet basis function, the number of decomposition layer was 3, “sqrtwolog” as the threshold, and “one” as

收稿日期: 2018-09-17 修回日期: 2018-11-21

基金项目: 国家自然科学基金项目(30871450)、广东省科技计划项目(2015A020224036、2014A020208109、2016A020210081)、广东省水利科技创新项目(2016-18)和广州市科技计划项目(201803020022)

作者简介: 岳学军(1971—),女,教授,博士生导师,主要从事农业工程、通信和信息技术应用研究,E-mail: yuexuejun@scau.edu.cn

noise estimation scheme, respectively. Thirdly, the features of SSAE in a specific stage were transferred and merged into baseline layer by layer to find out the best number of layers. The result showed that the best numbers of transferred layer were 3, 1, 4 and 3, and the corresponding values of determination coefficients for calibration set were 0.899 9, 0.859 8, 0.886 9 and 0.854 7 at germination, stability, bloom and picking stages, respectively, which were improved by 19.82%, 9.45%, 21.49% and 7.21%, respectively, compared with baseline. Then, the features of SSAE in the best layer were transferred and merged into baseline stage by stage to find out the best number of transferred stage. The experiment revealed that features of all four stages were transferred to its corresponding stage domain achieving the best performance. In this situation, the coefficients of determination for calibration set were 0.877 2, 0.898 1, 0.904 9 and 0.889 4 at germination, stability, bloom and picking stages, respectively, which were improved by 16.80%, 14.32%, 23.96% and 11.56%, respectively, compared with baseline. Fourthly, after performing wavelet de-noising and four kinds of spectrum transformation, i. e., the first derivative, second derivative, reciprocal and logarithm to the original spectrum, the layers' features and stages' features, which were obtained in SSAE previously, were transferred and merged into spectrum in four growth stages. When the first derivative spectrum was used as the input vector of the samples with wavelet de-noising, the SSAE - DLNs model achieved the best result and the coefficients of determination for calibration set were 0.899 2, 0.889 9, 0.883 8, 0.872 7 and 0.898 8, respectively, and the corresponding values of RMSE were 0.542 5, 0.549 6, 0.550 9, 0.553 9 and 0.544 3, respectively, and the corresponding values of sparse proportion were 0.141 1, 0.163 3, 0.118 9, 0.185 6 and 0.207 8, respectively, at germination, stability, bloom, picking stages and the whole growth period; and for the validation set, the coefficients of determination were 0.865 1, 0.870 4, 0.855 1, 0.858 0 and 0.877 1, respectively, and the corresponding values of RMSE were 0.569 3, 0.567 4, 0.578 6, 0.572 2 and 0.552 8, respectively. Comparing with traditional models such as support vector regression (SVR), partial least square regression (PLSR), general regression neural networks (GRNN) and stepwise multiple linear regression (SMLR), SSAE - DLNs model achieved the best performance, and the next was SVR, in which R^2 of calibration and validation set were 0.898 8 and 0.877 1, respectively. Finally, the research result proved the feasibility of monitoring potassium content of citrus leaves, which may provide a theoretical basis for growth monitoring and nutritional diagnosis of citrus trees.

Key words: citrus leaves; potassium content; deep transfer learning; stacked sparse autoencoder; hyperspectral; support vector regression

0 引言

钾(K)是柑橘生长过程中必需的营养元素之一,活性极高,对柑橘果实发育和品质形成起到十分重要的作用^[1]。我国是柑橘生产大国,快速无损测定柑橘叶片钾含量对柑橘生长健康状况、营养元素胁迫状况、柑橘产量预测和柑橘树的栽培管理、变量施肥施药、农机具研发等具有重要意义^[2]。

由于传统的作物钾含量检测方法存在耗时、费力、过程冗长繁琐、时效性差等弊端,因此研究快速无损的钾含量检测方法成为热点^[3]。随着高光谱技术的迅速发展,国内外研究者深入研究了作物营养成分光谱检测方法,但主要集中于氮素含量研究,对钾素含量研究较少^[4-6]。MENESATTI等^[7]基于近红外光谱对柑橘叶片包括钾在内的多种营养元素进行了估测,但缺乏对柑橘不同物候期的高光谱分析与建模。刘艳丽等^[8]基于高光谱技术分别建立了 iPLS 和 siPLS 模型的柑橘花钾素营养估测模型,

获得预测集相关系数最高为 0.885 5。朱西存等^[9]使用 ASD FieldSpec3 光谱仪测定苹果花期冠层高光谱数据,并对原始光谱进行了不同形式的光谱变换,获得一阶微分下多元线性回归(Multiple linear regression, MLR)模型的相关系数为 0.985 1,平均相对误差为 9.8%。赵化兵等^[10]对梨树鲜叶的可见/近红外反射光谱进行了 S-G(3)滤波,所建立的 PLSR 钾素含量模型的验证集和预测集决定系数为 0.722 7 和 0.679 1,预测的平均相对误差为 6.81%。以上方法中均没有涉及不同物候期光谱特征迁移,研究对象局限于某一时期,没有关注果树不同生长期的营养状况,由于叶片营养成分会不断变化,单一物候期的营养元素含量预测对整株果树生长周期营养状况监测不具备指导作用^[11]。同时上述方法所建立的单模型单数据集在特征提取和泛化能力上存在不足,均需收集相应数量的化学测量真实值作为模型训练监督标签,存在成本高、耗时间长、过程繁琐、工作量大缺点,不能实现不同目标域之间的特征

迁移和融合^[12-14]。

本文采用深度迁移学习方法对柑橘树4个不同物候期的高光谱数据进行自适应特征提取和降维,迁移和融合多种特征,以此建立SSAE-DLNs柑橘叶片钾含量估测模型。

1 材料与方法

1.1 柑橘树种植管理与叶片采集

选择广州市萝岗区蟹庄村柑橘种植示范园4年生的109株柑橘作为试验样本,并进行科学规范的种植管理,保证温度在12~20℃,灌水量1000mm左右,pH值为4~5,相对空气湿度为80%左右。采用纯度为45%的钾肥分别于萌芽期、稳果期、壮果促梢期和采果期进行施肥,施肥时间为2015年2、4、6、8月下旬,施肥量占全年施肥总量的30%、30%、25%、15%。保证水肥合理、稳定,灌溉频次为每周2次。分别在2015年4月24日(萌芽期)、6月22日(稳果期)、8月23日(壮果促梢期)、10月23日(采果期)采集柑橘叶片,在每棵树东南西北4个方位的上下两层共采集8片鲜叶,采集位于顶梢起向下数第3和第4片大小均匀的健康叶片。

1.2 高光谱测定

采用美国ASD FieldSpec 3光谱仪采集柑橘鲜叶的光谱反射值,光谱测量范围为350~2500nm,光谱数据输出间隔为1nm,故柑橘叶片的光谱数据为2151维矢量。具体操作是从叶片基部将叶片完整剪下,平铺于反射率近似为零的黑色橡胶上,采用ASD公司提供的Pro Lamp(A128932)人工光源通过手柄安装在采集支架上,入射光纤探头垂直正对待测叶片,距离叶片6cm,视场直径0.52cm,顶角30°,分别在每片叶子的叶尖、叶中和叶基附近采集3次^[15]。实际光谱反射值是叶尖至叶基光谱反射值的平均值。每次测量前均用白板校正,采集暗电流25次,白板10次^[16]。同一棵树同一生长时期的8片叶片光谱反射率的均值作为柑橘叶片样本的光谱反射率,不同生长时期的同一棵树视为不同样本,共有436个柑橘叶片样本。不同物候期109棵柑橘叶片样本的反射光谱如图1所示。

1.3 叶片钾含量测定

光谱测定后,选用火焰光度法测定柑橘叶片钾含量^[17],测定方法为将每株柑橘的8片鲜叶均匀混合,待测样品经消煮或浸提,然后稀释,用湿灰化法获取待测溶液,再用原子吸收光谱法进行钾素检测。钾质量分数统计数据如图2所示。从图2可知,不

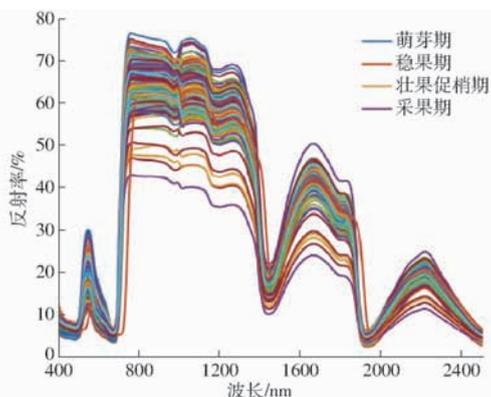


图1 不同物候期柑橘叶片样本反射光谱

Fig.1 Reflectance spectra of citrus samples at different growth stages

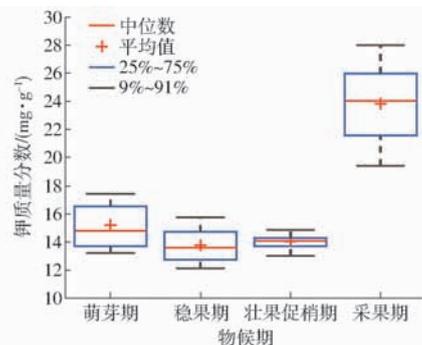


图2 不同物候期钾质量分数箱线图

Fig.2 Boxplot of potassium content at different growth stages

同物候期的柑橘叶片钾含量由大到小依次为采果期、萌芽期、壮果促梢期、稳果期。

1.4 高光谱数据预处理方法

在高光谱数据获取过程中,由于测定环境、仪器噪声等因素影响,不可避免存在多重共线性、吸光度的非线性、附加散射变动和基线变动。原始光谱维度高,相邻波段存在较大相关性,造成数据冗余^[18]。本文分别采用连续投影算法(Successive projections algorithm, SPA)和小波去噪对原始光谱进行预处理。

SPA是一种常用的光谱特征波长选取算法,能使从光谱变量中选出的变量组共线性最小、冗余信息最少。柑橘在不同物候期对钾素的需求不同,不同物候期的光谱反射率综合表征其生理和物理化学组分状态,通过SPA降维方法,提取光谱中敏感波段^[19]。

利用小波去噪方法,首先选定小波基函数和分解层次对原始数据进行分解,然后根据各层阈值去除分解后小波系数较小的成分,最后通过小波逆变换重构信号^[20]。试验中采用正交试验和极差分析对小波去噪结果进行筛选,选出小波去噪参数最优水平组合。

1.5 建模原理与评价标准

堆栈稀疏编码器 (Stacked sparse autoencoder, SSAE) 是一种多层神经网络, 能自适应获取特征层, SSAE 的特征分享层能够学习到不同任务之间的特征和噪声共性模式, 既能专注于特定特征, 也能提供共性特征^[21]。本文将堆栈稀疏自动编码器堆叠起来组成特征分享层^[22], 用于捕获多任务中共同特征, 减少目标函数岭、脊和鞍点, 加快迭代速率, 优化和提高深度学习模型预测精度和泛化能力。

设 SSAE 的稀疏度为 ρ , 网络激活函数为 σ , 整个 SSAE 定义 KL (Kullback - Leibler) 散度^[23] 为

$$K_L(\rho \parallel \hat{\rho}_j) = \rho \lg \frac{\rho}{\hat{\rho}_j} + (1 - \rho) \lg \frac{1 - \rho}{1 - \hat{\rho}_j} \quad (1)$$

其中
$$\hat{\rho}_j = \frac{1}{m} \sum_{j=1}^m \sigma(z^j) \quad (2)$$

式中 $\hat{\rho}_j$ ——第 j 个神经元稀疏度
 m ——第 j 个神经元与它前向相连接的神经元数量
 z ——神经元加权输入值

设 SSAE 网络权重矩阵为 \mathbf{W} , 网络偏置向量为 \mathbf{b} , 第 l 层神经元数量为 s_l , 隐含层总数为 n_l , 调和因子为 β , 原损失函数为 $J(\mathbf{W}, \mathbf{b})$, 稀疏损失函数 $J_s(\mathbf{W}, \mathbf{b})$ 为

$$J_s(\mathbf{W}, \mathbf{b}) = J(\mathbf{W}, \mathbf{b}) + \beta \sum_{l=1}^{n_l} \sum_{j=1}^{s_l} K_L(\rho \parallel \hat{\rho}_j) \quad (3)$$

DLNs 深度学习模型在特征提取上具有自适应性, 并且能够融合不同分布概率的光谱特征, 提高模型精度、稳定性、泛化能力和迁移能力^[24-26]。设源

域为 D_s , 目标域为 D_T , 假设函数为 h , 正则函数为 Ω , 最小化损失函数 Ψ 为

$$\min_{\Theta} \Psi = \frac{1}{n_T} \sum_{j=1}^{n_T} \frac{1}{2} \| h(\mathbf{X}_j^T) - \mathbf{y}_j^T \|^2 + \Omega \quad (4)$$

式中 Θ —— D_s 迁移至 D_T 的网络参数
 \mathbf{X}_j ——目标域第 j 个输入矩阵
 \mathbf{y}_j ——目标域第 j 个输出向量
 n_T ——目标域样本总数

从总样本数中随机选取 80% 的样本 (349 个样本) 作为校正集 (Calibration set), 用于训练模型, 剩余 20% (87 个样本) 作为验证集 (Validation set), 用于评估模型, 建模评估采用模型决定系数 R^2 和均方根误差 (Root mean square error, RMSE) 两个指标^[27]。试验数据处理与建模流程为: 先进行 SPA 降维, 将提取的特征光谱用于建立 MLR 模型; 同时采用小波去噪和 SSAE 特征提取和迁移方法, 分别建立 DLNs 模型, 对比分析基于传统单一特征与 SSAE 迁移特征下模型的最终效果。SSAE - DLNs 试验中采用基于随机梯度下降的 BP 算法训练网络, 设置传输函数为 logsig^[28], 最大迭代次数为 1 200, 最佳神经元数量采用格点搜索法 (Grid search) 和交叉验证法 (Cross validation) 选得最优值。每个试验方案均取 20 次运行结果的均值作为最终记录。

2 结果与分析

2.1 最优 SPA 和 MLR 建立与验证

通过交叉验证方法, 选取最优 SPA 降维结果。波长按重要性由大到小排列, 试验结果如表 1 所示。

表 1 不同物候期钾质量分数特征波段

Tab.1 Characteristic bands of potassium content at different growth stages

物候期	特征波长/nm	平均相关系数	波段数
萌芽期	357, 364, 378, 1 600, 352, 361, 1 872, 761, 355, 359, 713, 688, 366, 367	0.499 0	14
稳果期	357, 416, 396, 352, 351, 355, 401, 360, 420, 391, 408, 364, 353, 406, 409, 370, 380	0.501 8	17
壮果促梢期	358, 359, 356, 391, 367, 360, 370, 1 001, 369, 366, 745	0.381 5	11
采果期	357, 383, 356, 717, 1 435, 663, 381, 1 935, 1 937, 2 496	0.634 5	10
全育期	2 311, 2 255, 1 336, 441, 445, 455, 466, 556, 444, 2 116, 2 018, 406, 357, 515, 437, 1 253, 2 499, 433, 430,	0.603 1	73
	431, 412, 415, 426, 1 836, 402, 403, 1 922, 978, 422, 427, 768, 716, 378, 1 091, 420, 416, 417, 405, 397, 398, 424, 423, 408, 1 517, 1 399, 392, 355, 364, 381, 657, 390, 434, 363, 419, 373, 384, 394, 694, 369, 353, 413, 351, 395, 410, 483, 401, 360, 448, 376, 387, 684, 2 489, 359, 377, 371, 367		

由表 1 可知, 钾素明显存在特征光谱漂移现象, 不同生长期的特征光谱分布情况不同, 特征波段数量多、跨度广、构成复杂。随着生长期推移, 钾素反射光谱有部分重要的特征波段向高波段漂移。萌芽期特征波长主要集中在 1 000 nm 内, 采果期有部分特征光谱漂移至 1 935 ~ 2 007 nm 和 2 496 ~ 2 500 nm。

将原始反射光谱进行一阶微分, 结果如图 3 所

示。在 490 ~ 530 nm 波段, 柑橘叶片钾含量越低, 蓝边面积越大, 这是由于柑橘缺钾素时, 叶绿素含量降低, 反射蓝绿光增加; 在 540 ~ 660 nm 波段, 一阶微分越大, 钾含量越大, 对应原始反射光谱 650 nm 处有一个红光吸收谷, 随钾含量降低, 叶绿素含量下降, 光合作用利用的红光减少, 吸收谷变浅。780 ~ 1 100 nm 波段范围内, 一阶微分的和越大, 钾含量越

高,可能与缺钾导致叶片表皮细胞发生变化,叶片厚度增加,叶片栅栏、海绵组织的细胞收缩和局部破裂有关。1 900 ~ 2 010 nm 波段范围内,一阶微分的和越大,钾含量越高,其内在的生理生化机理还有待研究^[29-30]。

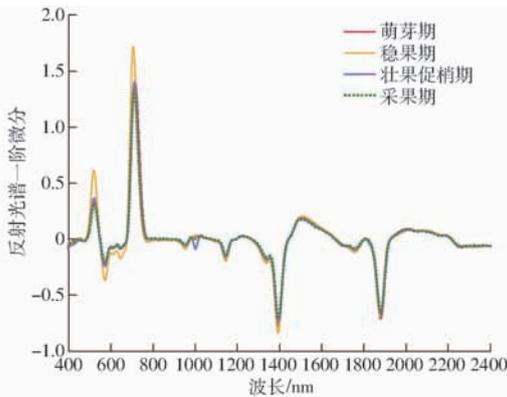


图3 柑橘叶片反射光谱一阶微分

Fig. 3 First order derivative of reflectance spectra for citrus

将 SPA 降维后的数据作为输入量,建立 MLR 模型^[31],结果如表 2 所示。

表 2 不同物候期 MLR 建模性能评估

Tab. 2 Performance evaluation of MLR model at different growth stages

物候期	R_c^2	RMSE _c	R_v^2	RMSE _v
萌芽期	0.751 0	5.799 0	0.576 5	8.916 5
稳果期	0.785 6	4.742 0	0.639 2	7.776 3
壮果促梢期	0.730 0	6.175 5	0.615 6	8.868 1
采果期	0.797 2	4.472 0	0.659 2	7.276 3
全育期	0.798 5	4.050 1	0.718 0	6.680 0

注: R_c^2 、RMSE_c、 R_v^2 、RMSE_v分别表示校正集模型决定系数、校正集均方根误差、验证集模型决定系数、验证集均方根误差,下同。

从表 2 可知,MLR 模型的 R^2 偏低,萌芽期、稳果期、壮果促梢期、采果期验证集决定系数 R_v^2 分别为 0.576 5、0.639 2、0.615 6、0.659 2, RMSE_v 达到 8.916 5、7.776 3、8.868 1、7.276 3,模型预测误差大,鲁棒性和泛化能力低,说明柑橘叶片中钾素的反射率光谱样本空间中存在大量非线性关系特征,需探索基于深度学习的多重非线性反演方法。

2.2 小波去噪和 DLNs 建模结果与分析

小波分解过程中涉及小波基函数、分解层数以及光谱重构过程中的阈值方案、阈值调整方案等参数,据文献表明,分解层数大于 7 时,对建模效果没有明显的提升作用^[32]。由于小波去噪涉及因素多,采用正交试验,根据文献^[33],正交试验的预选小波基函数选取 haar、db4、sym8、coif2,能达到良好效果。正交试验的因素水平^[34]如表 3 所示。

表 3 正交试验因素水平

Tab. 3 Factors and levels of orthogonal test

水平	因素			
	小波基函数 A	分解层数 B	阈值方案 C	噪声估计方案 D
1	haar	1	rigrsure	one
2	db4	3	heursure	sln
3	sym8	5	sqtwolog	mln
4	coif2	7	minimaxi	

从表 3 中可以看出,该正交试验包括 3 因素 4 水平和 1 因素 3 水平两类。因此,采用拟水平法,将因素 D 的第 3 水平进行重复,构成 4 因素 4 水平,直接采用正交表 $L_{16}(4^5)$ 进行正交试验。虽然拟水平后的表对所有因素来说不具有均衡搭配性质,但仍具有部分均衡搭配的性质,因此拟水平法仍保留了正交表的优点。小波去噪参数正交试验结果见表 4。针对 5 个物候期,采用极差分析法对小波去噪正交试验的结果进行分析,试验结果见表 5。

从表 4 知,第 14 组水平组合的校正集和验证集模型决定系数均达到最大,分别为 0.887 9、0.875 2,比基于原始光谱建模的 R^2 提高了 9.25% 和 8.42%;校正集和验证集模型的均方根误差达到最小,分别为 0.343 6、0.314 8,比基于原始光谱建模的 RMSE 降低了 56.95% 和 61.89%,与表 5 的分析一致,即最优水平组合是 $A_4B_2C_3D_1$,即小波基函数为 coif2,分解层数为 3,阈值方案为 sqtwolog,噪声估计方案为 one。本试验采用 $A_4B_2C_3D_1$ 方案对所有光谱进行去噪。

2.3 SSAE 和 DLNs 建模结果与分析

2.3.1 SSAE 中光谱特征状态

SSAE 试验中权重状态见图 4。由图 4 可知,SSAE 能够对不同物候期的光谱自适应获取光谱非线性特征,物候期间特征光谱存在交集。在前层单元对后层单元的关系中,萌芽期、稳果期、壮果促梢期、采果期的 SSAE 神经元归一化活跃度超过 0.5,分别占总神经元数的 23.36%、37.08%、3.10%、20.96%,平均活跃度分别为 0.361 5、0.399 0、0.280 7、0.156 4,4 个物候期的前层单元活跃神经元主要分布于 67 ~ 86、100 ~ 105、135 ~ 145、14 ~ 39、69 ~ 81 和 150 ~ 160 号神经单元上。

2.3.2 同一物候期特征层间迁移与融合

研究柑橘同一物候期光谱在 SSAE 中每层特征迁移融合与层数之间的关系,依次融合基准层和特征迁移层,得到深度学习网络模型性能如图 5 所示(图中 * 表示极大值,横坐标 0 表示基准层)。

表 4 小波去噪正交试验结果

Tab. 4 Grouping and result of wavelet denoising orthogonal test

试验序号	A	B	C	D	R_c^2	RMSE _c	R_v^2	RMSE _v
1	haar	1	rigrsure	one	0.842 0	0.548 3	0.824 6	0.650 1
2	haar	3	heursure	sln	0.860 8	0.492 9	0.823 9	0.655 8
3	haar	5	sqtwolog	mln	0.829 6	0.595 8	0.802 3	0.839 9
4	haar	7	minimaxi	mln'	0.826 3	0.625 9	0.810 1	0.815 5
5	db4	1	heursure	mln	0.814 2	0.648 6	0.802 9	0.832 3
6	db4	3	rigrsure	mln'	0.858 6	0.498 6	0.833 8	0.568 7
7	db4	5	minimaxi	one	0.812 8	0.796 1	0.804 0	0.830 0
8	db4	7	sqtwolog	sln	0.845 3	0.516 3	0.832 6	0.585 8
9	sym8	1	sqtwolog	mln'	0.854 6	0.492 3	0.847 6	0.514 1
10	sym8	3	minimaxi	mln	0.872 8	0.445 2	0.852 5	0.507 5
11	sym8	5	rigrsure	sln	0.819 5	0.685 0	0.802 0	0.844 5
12	sym8	7	heursure	one	0.814 0	0.685 8	0.809 4	0.824 0
13	coif2	1	minimaxi	sln	0.869 6	0.499 8	0.839 7	0.559 2
14	coif2	3	sqtwolog	one	0.887 9	0.343 6	0.875 2	0.314 8
15	coif2	5	heursure	mln'	0.874 0	0.328 3	0.850 5	0.504 8
16	coif2	7	rigrsure	mln	0.867 5	0.486 3	0.845 3	0.520 2
原始光谱					0.812 7	0.798 1	0.807 2	0.826 0

表 5 小波去噪正交试验结果极差分析

Tab. 5 Analysis result of wavelet denoising orthogonal test

评价指标	A		B		C		D	
	R_c^2	R_v^2	R_c^2	R_v^2	R_c^2	R_v^2	R_c^2	R_v^2
H_1	0.839 7	0.815 2	0.845 1	0.828 7	0.846 9	0.826 4	0.867 2	0.849 0
H_2	0.832 7	0.818 3	0.870 0	0.846 4	0.840 8	0.821 7	0.839 2	0.828 3
H_3	0.840 2	0.827 9	0.834 0	0.814 7	0.854 4	0.839 4	0.832 2	0.812 3
H_4	0.874 8	0.852 7	0.838 3	0.824 4	0.845 4	0.826 6		
R	0.042 0	0.037 4	0.036 1	0.031 7	0.013 6	0.017 8	0.035 1	0.036 7
优水平	A_4	A_4	B_2	B_2	C_3	C_3	D_1	D_1

注: $H_1 \sim H_4$ 为某一水平的评价指标均值;R 为极差。

由图 5 可知,随着迁移层数增加,意味着增加了特征数,DLNs 模型性能得到提高。当因 SSAE 特征迁移层数增加而引入的噪声影响大于所引入的特征数时,模型性能开始下降且不稳定。在特征层数迁移中,萌芽期、稳果期、采果期超过极大值后,开始迅速下降。壮果促梢期超过极大值后在第 8 层出现第 2 极大值,考虑到迁移层数过大会引入高增量噪声和增加模型复杂度,影响模型鲁棒性,故壮果促梢期最优层数选择 4。所以试验中萌芽期、稳果期、壮果促梢期、采果期最优迁移层数分别为 3、1、4、3, R^2 分别为 0.899 9、0.859 8、0.886 9、0.854 7,比原始基准层分别提高了 19.82%、9.45%、21.49%、7.21%。

2.3.3 不同物候期光谱特征迁移与融合

为研究柑橘光谱不同物候期的特征迁移域对目

标域的影响,将其他域数据集依次通过 SSAE 提取特征后,依次迁移至目标域,其中基准目标域(Benchmark target domain, BTD)性能来自 MLR 模型。萌芽期、稳果期、壮果促梢期、采果期分别记作 GP、SP、BP、PP,TD-q($q = 1, 2, 3, 4$)表示 4 个物候期迁移域的组合 C_q^4 ,迁移到目标域(Target domain, TD)的特征来自 C_q^4 构成的新域在目标域的特征提取,表示迁移 q 个物候期特征到 TD。如萌芽期的 TD-1 表示来自单物候期{GP}、{SP}、{BP}、{PP}所构成的 4 个新域在萌芽期域进行特征提取和融合。试验结果取均值,如图 6 所示。

由图 6 可知,SSAE 不同物候期的迁移特征能明显提高目标域的性能,1 个物候期迁移域便能明显提高基准目标域的性能。随着迁移域增加,目标域性能提高速率减缓,逐步达到饱和状态,意味着

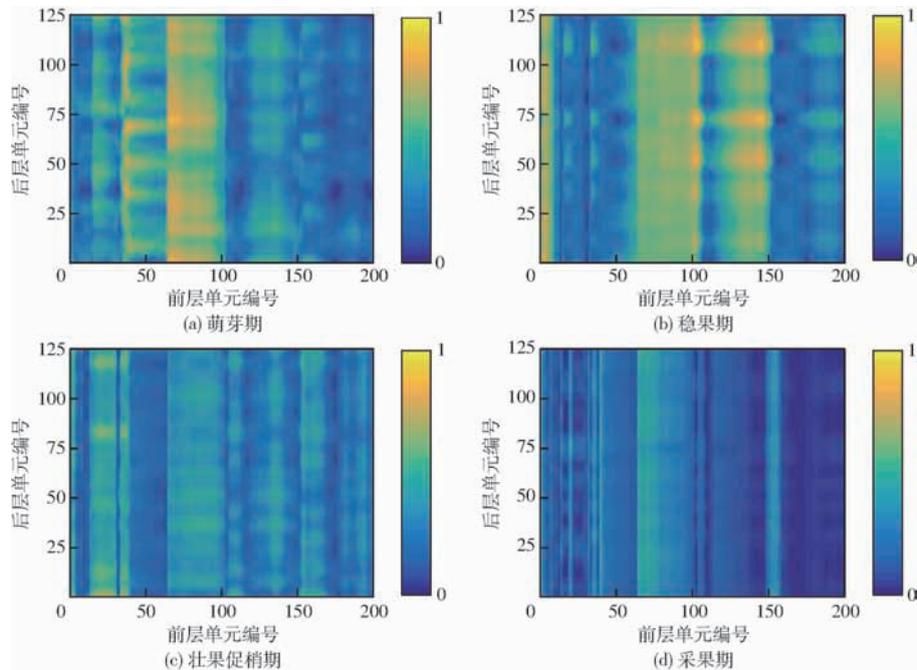


图4 不同物候期间SSAE归一化权重

Fig.4 Normalized weights of SSAE at different growth stages

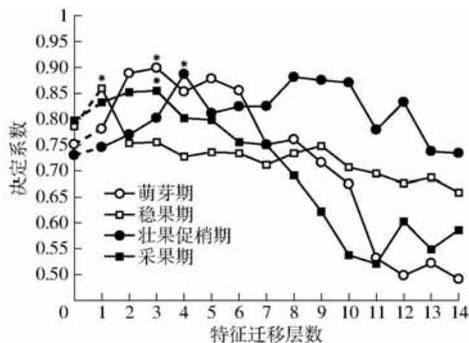


图5 特征层数对模型性能影响

Fig.5 Influence of characteristic layers on model performance

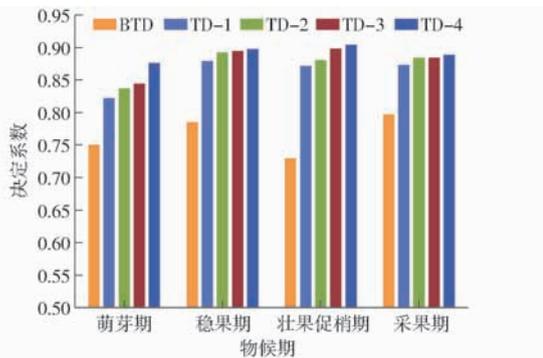


图6 迁移域数与决定系数关系

Fig.6 Relationship between number of transfer domains and determination coefficient

新迁移域所引入的相关特征对目标域贡献率减低而变得相对不明显。由图6可知,试验中最佳迁移域为4,对应的萌芽期、稳果期、壮果促梢期、采果期最佳 R^2 分别为0.8772、0.8981、0.9049、0.8894,比BTD分别提高了16.80%、14.32%、23.96%、

11.56%。

根据以上分析,本文对萌芽期、稳果期、壮果促梢期、采果期4个物候期试验选择SSAE的迁移层数分别为3、1、4、3,每个目标域的迁移域数为4。结合2.2节部分,对所有光谱进行小波去噪后,研究和对比多种不同光谱形式的DLNs建模,该模型的最佳稀疏度采用留一交叉验证法来选定,试验结果见表6。

从表6可知,一阶导数谱 r' 建模效果最好,萌芽期、稳果期、壮果促梢期、采果期和全生长期的校正集模型决定系数分别为0.8992、0.8899、0.8838、0.8727和0.8988,稀疏度分别为0.1411、0.1633、0.1189、0.1856和0.2078,验证集模型决定系数分别为0.8651、0.8704、0.8551、0.8580和0.8771;倒数谱 $1/r$ 建模效果最差,萌芽期、稳果期、壮果促梢期、采果期和全生长期的校正集模型决定系数分别为0.8157、0.7916、0.8012、0.7819和0.8012,验证集模型决定系数分别为0.8096、0.7806、0.7916、0.7751和0.8009;原始光谱 r 的建模效果仅次于—阶导数谱 r' ,而对数谱 $\lg r$ 和二阶导数谱 r'' 的建模效果皆低于原始光谱 r 。

2.4 其他模型建模对比分析

本试验将最优的基于SSAE-DLNs和其他模型进行对比,目前在基于高光谱反射率对营养元素反演中的主流模型主要包括支持向量回归(Support vector regression, SVR)、偏最小二乘法回归(Partial least square regression, PLSR)、广义神经网络(General regression neural networks, GRNN)、逐步多

元线性回归 (Stepwise multiple linear regression, SMLR) 等。将全生长期的光谱经过小波去噪后的

一阶导数谱 r' 导入这 4 个模型, 模型参数分别调节到最优, 结果如图 7 所示。

表 6 不同光谱变换形式的模型性能评估

Tab. 6 Model performance evaluation on calibration set with different transformations of spectral data

数据集	光谱变换形式	萌芽期			稳果期			壮果促梢期			采果期			全生长期		
		稀疏度	R^2	RMSE												
校正集	r	0.185 6	0.855 5	0.579 2	0.118 9	0.858 7	0.574 6	0.163 3	0.865 8	0.561 2	0.163 3	0.864 5	0.575 1	0.230 0	0.869 0	0.565 9
	r'	0.141 1	0.899 2	0.542 5	0.163 3	0.889 9	0.549 6	0.118 9	0.883 8	0.550 9	0.185 6	0.872 7	0.553 9	0.207 8	0.898 8	0.544 3
	r''	0.052 2	0.828 0	0.616 1	0.074 4	0.809 2	0.669 0	0.118 9	0.828 8	0.608 7	0.074 4	0.822 2	0.632 0	0.185 6	0.846 3	0.586 1
	$1/r$	0.030 0	0.815 7	0.642 2	0.052 2	0.791 6	0.690 2	0.096 7	0.801 2	0.683 6	0.030 0	0.781 9	0.711 4	0.163 3	0.801 2	0.685 3
	$\lg r$	0.163 3	0.831 4	0.594 5	0.141 1	0.818 9	0.639 3	0.185 6	0.825 7	0.620 1	0.118 9	0.801 1	0.685 5	0.230 0	0.846 0	0.582 3
验证集	r	0.185 6	0.842 6	0.590 0	0.118 9	0.832 0	0.598 3	0.163 3	0.840 4	0.590 4	0.163 3	0.850 1	0.582 0	0.230 0	0.846 3	0.580 9
	r'	0.141 1	0.865 1	0.569 3	0.163 3	0.870 4	0.567 4	0.118 9	0.855 1	0.578 6	0.185 6	0.858 0	0.577 2	0.207 8	0.877 1	0.552 8
	r''	0.052 2	0.813 0	0.646 9	0.074 4	0.804 3	0.679 2	0.118 9	0.810 3	0.654 2	0.074 4	0.817 6	0.640 3	0.185 6	0.833 3	0.596 6
	$1/r$	0.030 0	0.809 6	0.663 8	0.052 2	0.780 6	0.725 8	0.096 7	0.791 6	0.694 3	0.030 0	0.775 1	0.740 8	0.163 3	0.800 9	0.688 1
	$\lg r$	0.163 3	0.829 7	0.600 3	0.141 1	0.804 9	0.671 1	0.185 6	0.811 1	0.652 0	0.118 9	0.791 3	0.700 1	0.230 0	0.834 1	0.598 8

注: $r, r', r'', 1/r, \lg r$ 分别为原始光谱、一阶导数谱、二阶导数谱、倒数谱、对数谱。

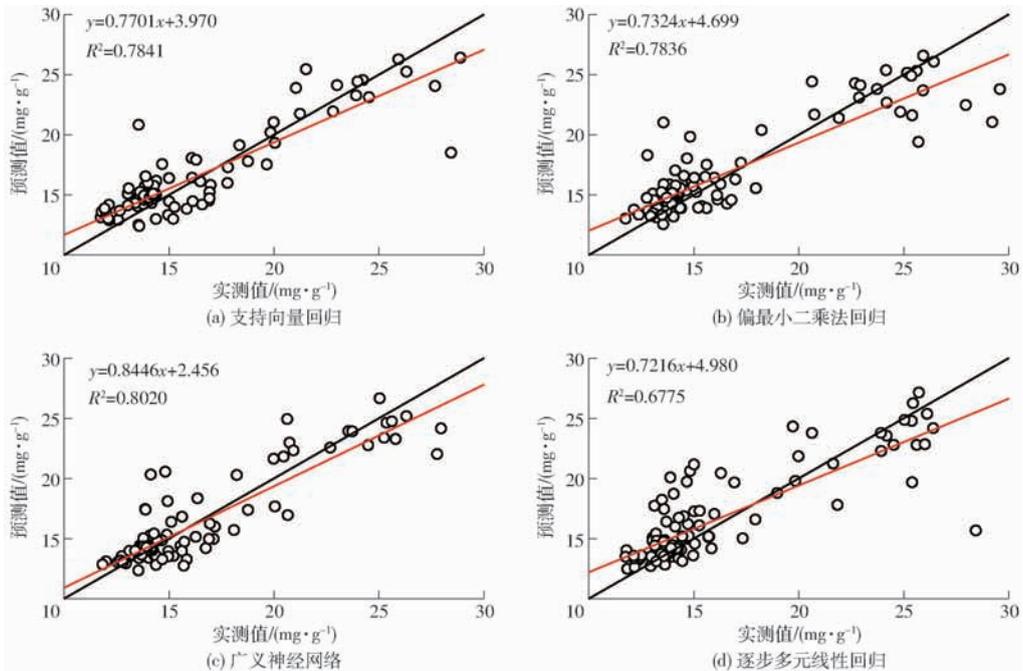


图 7 不同建模方法下钾质量分数实测值和预测值的比较

Fig. 7 Comparison of measured and predicted potassium contents by using different modeling methods

图 7 不同模型与表 6 中最优 SSAE - DLNs 模型相比, 性能均有不同程度下降, 主要原因是钾素特征光谱中含有大量复杂的非线性特征, 而较为简单的模型无法得到特征变量间更复杂的关系。SSAE 模型能够自适应不同物候期的光谱特征并能相应提取有效成分, 能对小波去噪后的一阶导数谱具有最大解释能力。DLNs 模型能对不同物候期的光谱域进行特征迁移和融合, 可以比单模型单任务带来更丰富的信息。因此 SSAE - DLNs 模型具有更好的预测精度和泛化能力, 能自适应不同时期的光谱反演任务。

3 结论

(1) 为了降低数据噪声对深度学习网络的影响, 采用小波去噪方法对光谱进行预处理。通过正交试验和极差分析, 小波去噪最优水平组合是 $A_4 B_2 C_3 D_1$, 即小波基函数为 coif2 , 分解层数为 3, 阈值方案为 sqtwolog , 噪声估计方案为 one 。

(2) 试验采用了 SSAE 模型实现柑橘不同物候期特征提取和迁移, 自适应获取光谱中非线性特征; 采用了 DLNs 模型进行物候期间的光谱特征融合和钾含量反演。SSAE 模型的前层单元中神经元平均

活跃度分别为 0.361 5、0.399 0、0.280 7、0.156 4。SSAE 中萌芽期、稳果期、壮果促梢期、采果期的最优迁移层数分别为 3、1、4、3，模型决定系数分别为 0.899 9、0.859 8、0.886 9、0.854 7，比原始基准层分别提高了 19.82%、9.45%、21.49%、7.21%。每个目标域的最优迁移域数为 4，萌芽期、稳果期、壮果促梢期、采果期模型最佳决定系数分别为 0.877 2、0.898 1、0.904 9、0.889 4，比基准目标域分别提高了 16.80%、14.32%、23.96%、11.56%。

(3) 比较了不同光谱变换形式的建模效果，将原始光谱分别变换为多种光谱形式，导入 SSAE-DLNs 模型训练，试验结果表明，一阶导数谱 r' 建模效果最好，萌芽期、稳果期、壮果促梢期、采果期和全

生长期的校正集模型决定系数分别为 0.899 2、0.889 9、0.883 8、0.872 7 和 0.898 8，稀疏度分别为 0.141 1、0.163 3、0.118 9、0.185 6 和 0.207 8，验证集模型决定系数分别为 0.865 1、0.870 4、0.855 1、0.858 0 和 0.877 1。光谱变换形式的建模效果由大到小依次为 r' 、 r 、 r'' 、 $\lg r$ 、 $1/r$ 。

(4) 对比了小波去噪后一阶微分光谱建模的 SSAE-DLNs、SVR、PLSR、GRNN、SMLR 模型性能，SSAE-DLNs 效果最优， R_c^2 和 R_v^2 分别为 0.898 8、0.877 1。

(5) 不同物候期的柑橘叶片钾含量由大到小依次为采果期、萌芽期、壮果促梢期、稳果期。不同物候期施肥量表明不同时期叶片钾含量变化呈现一定的规律，但与施肥量之间并不是严格线性关系。

参 考 文 献

- [1] 黄双萍, 岳学军, 洪添胜, 等. 不同物候期柑橘叶片钾素水平预测建模[J]. 江苏大学学报(自然科学版), 2013, 34(5): 529-535. HUANG Shuangping, YUE Xuejun, HONG Tiansheng, et al. Potassium content prediction model of citrus leaves in different phenological period[J]. Journal of Jiangsu University(Natural Science Edition), 2013, 34(5): 529-535. (in Chinese)
- [2] 章胜勇, 祁春节. 我国柑橘鲜果滞销的原因及对策分析[J]. 华南农业大学学报(社会科学版), 2008, 7(4): 75-83. ZHANG Shengyong, QI Chunjie. Analysis of the causes and countermeasures against the slow sale of citrus fruit in China[J]. Journal of South China Agricultural University(Social Science Edition), 2008, 7(4): 75-83. (in Chinese)
- [3] LIU Fei, NIE Pengcheng, HUANG Min, et al. Nondestructive determination of nutritional information in oilseed rape leaves using visible/near infrared spectroscopy and multivariate calibrations[J]. Science China Information Sciences, 2011, 54(3): 598-608.
- [4] ABDEL-RAHMAN E M, AHMED F B, ISMAIL R. Random forest regression and spectral band selection for estimating sugarcane leaf nitrogen concentration using EO-1 Hyperion hyperspectral data[J]. International Journal of Remote Sensing, 2013, 34(2): 712-728.
- [5] 黄双萍, 洪添胜, 岳学军, 等. 基于高光谱的柑橘叶片氮素含量多元回归分析[J]. 农业工程学报, 2013, 29(5): 132-138. HUANG Shuangping, HONG Tiansheng, YUE Xuejun, et al. Multiple regression analysis of citrus leaf nitrogen content using hyperspectral technology[J]. Transactions of the CSAE, 2013, 29(5): 132-138. (in Chinese)
- [6] TONG Peijin, DU Yiping, ZHENG Kaiyi, et al. Improvement of NIR model by fractional order Savitzky-Golay derivation (FOSGD) coupled with wavelength selection[J]. Chemometrics and Intelligent Laboratory Systems, 2015, 143: 40-48.
- [7] MENESATTI P, ANTONUCCI F, PALLOTTINO F, et al. Estimation of plant nutritional status by vis-NIR spectrophotometric analysis on orange leaves [J]. Biosystems Engineering, 2010, 105(4): 448-454.
- [8] 刘艳丽, 何绍兰, 吕强, 等. 柑橘花钾素营养的高光谱表征[J]. 果树学报, 2014, 31(6): 1065-1071. LIU Yanli, HE Shaolan, LÜ Qiang, et al. Characteristics of potassium content in citrus flowers with hyperspectral imagery[J]. Journal of Fruit Science, 2014, 31(6): 1065-1071. (in Chinese)
- [9] 朱西存, 姜远茂, 赵庚星, 等. 基于模糊识别的苹果花期冠层钾素含量高光谱估测[J]. 光谱学与光谱分析, 2013, 33(4): 1023-1027. ZHU Xicun, JIANG Yuanmao, ZHAO Gengxing, et al. Hyperspectral estimation of kalium content in apple florescence canopy based on fuzzy recognition[J]. Spectroscopy and Spectral Analysis, 2013, 33(4): 1023-1027. (in Chinese)
- [10] 赵化兵, 王洁, 董彩霞, 等. 基于可见/近红外反射光谱的梨树叶片钾含量的快速测定研究[J]. 土壤, 2014, 46(2): 256-261. ZHAO Huabing, WANG Jie, DONG Caixia, et al. Fast determination of potassium content in fresh pear leaves using visible/near infrared spectroscopy technique[J]. Soils, 2014, 46(2): 256-261. (in Chinese)
- [11] 屈莎, 李振海, 邱春霞, 等. 基于开花期氮素营养指标的冬小麦籽粒蛋白质含量遥感预测[J]. 农业工程学报, 2017, 33(12): 186-193. QU Sha, LI Zhenhai, QIU Chunxia, et al. Remote sensing prediction of winter wheat grain protein content based on nitrogen nutrition index at anthesis stage[J]. Transactions of the CSAE, 2017, 33(12): 186-193. (in Chinese)
- [12] PAN S J, YANG Qiang. A survey on transfer learning[J]. IEEE Transactions on Knowledge and Data Engineering, 2010, 22(10): 1345-1359.
- [13] BARNETT S M, CECI S J. When and where do we apply what we learn? A taxonomy for far transfer[J]. Psychological Bulletin, 2002, 128(4): 612-637.
- [14] LU Jie, BEHBOOD V, HAO Peng, et al. Transfer learning using computational intelligence: a survey[J]. Knowledge-Based Systems, 2015, 80(Supp.): 14-23.
- [15] 岳学军, 全东平, 洪添胜, 等. 不同生长期柑橘叶片磷含量的高光谱预测模型[J]. 农业工程学报, 2015, 31(8): 207-213.

- YUE Xuejun, QUAN Dongping, HONG Tiansheng, et al. Prediction model of phosphorus content for citrus leaves during different growth periods based on hyperspectrum[J]. Transactions of the CSAE, 2015, 31(8): 207–213. (in Chinese)
- [16] 岳学军,全东平,洪添胜,等. 柑橘叶片叶绿素含量高光谱无损检测模型[J]. 农业工程学报,2015,31(1):294–302.
YUE Xuejun, QUAN Dongping, HONG Tiansheng, et al. Non-destructive hyperspectral measurement model of chlorophyll content for citrus leaves[J]. Transactions of the CSAE, 2015, 31(1): 294–302. (in Chinese)
- [17] MAHAJAN G R, SAHOO R N, PANDEY R N, et al. Using hyperspectral remote sensing techniques to monitor nitrogen, phosphorus, sulphur and potassium in wheat (*Triticum aestivum* L.)[J]. Precision Agriculture, 2014, 15(5): 499–522.
- [18] GÓMEZ-CASERO M T, LÓPEZ-GRANADOS F, PEÑA-BARRAGÁN J M, et al. Assessing nitrogen and potassium deficiencies in olive orchards through discriminant analysis of hyperspectral data[J]. Journal of the American Society for Horticultural Science, 2007, 132(5): 611–618.
- [19] WU Di, WU Hongxi, CAI Jingbo, et al. Classifying the species of exopalaemon by using visible and near infrared spectra with uninformative variable elimination and successive projections algorithm[J]. Journal of Infrared and Millimeter Waves, 2009, 28(6):423–427.
- [20] 邓小蕾,李民赞,郑立华,等. 基于反射光谱预处理的苹果叶片叶绿素含量预测[J]. 农业工程学报,2014,30(14):140–147.
DENG Xiaolei, LI Minzan, ZHENG Lihua, et al. Estimating chlorophyll content of apple leaves based on preprocessing of reflectance spectra[J]. Transactions of the CSAE, 2014, 30(14): 140–147. (in Chinese)
- [21] TAO Chao, PAN Hongbo, LI Yansheng, et al. Unsupervised spectral-spatial feature learning with stacked sparse autoencoder for hyperspectral imagery classification[J]. IEEE Geoscience and Remote Sensing Letters, 2015, 12(12): 2438–2442.
- [22] ZABALZA J, REN J, ZHENG Jiangbin, et al. Novel segmented stacked autoencoder for effective dimensionality reduction and feature extraction in hyperspectral imaging[J]. Neurocomputing, 2016, 185: 1–10.
- [23] ZHAO Chunhui, WAN Xiaoqing, ZHAO Genping, et al. Spectral-spatial classification of hyperspectral imagery based on stacked sparse autoencoder and random forest[J]. European Journal of Remote Sensing, 2017, 50(1): 47–63.
- [24] HINTON G E, SALAKHUTDINOV R R. Reducing the dimensionality of data with neural networks[J]. Science, 2006, 313(5786): 504–507.
- [25] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. Nature, 2015, 521(7553): 436–444.
- [26] 岳学军,凌康杰,洪添胜,等. 基于高光谱图像的龙眼叶片叶绿素含量分布模型[J/OL]. 农业机械学报, 2018, 49(8): 18–25.
YUE Xuejun, LING Kangjie, HONG Tiansheng, et al. Distribution model of chlorophyll content for longan leaves based on hyperspectral imaging technology[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2018, 49(8):18–25. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20180802&journal_id=jcsam. DOI: 10.6041/j.issn.1000-1298.2018.08.002. (in Chinese)
- [27] 孙俊,丛孙丽,毛罕平,等. 基于高光谱的油麦菜叶片水分 CARS-ABC-SVR 预测模型[J]. 农业工程学报,2017, 33(5):178–184.
SUN Jun, CONG Sunli, MAO Hanping, et al. CARS-ABC-SVR model for predicting leaf moisture of leaf-used lettuce based on hyperspectral[J]. Transactions of the CSAE, 2017, 33(5): 178–184. (in Chinese)
- [28] ZHOU Weixun, SHAO Zhenfeng, DIAO Chunyuan, et al. High-resolution remote-sensing imagery retrieval using sparse features by auto-encoder[J]. Remote Sensing Letters, 2015, 6(10): 775–783.
- [29] 王珂,沈掌泉,ABOU-ISMAIL O,等. 不同钾营养水平的水稻冠层和叶片光谱特征研究初报[J]. 科技通报,1997,13(4): 211–214.
WANG Ke, SHEN Zhangquan, ABOU-ISMAIL O, et al. Preliminary study on canopy and leaf reflectance characteristics of rice with various potassium levels[J]. Bulletin of Science and Technology, 1997, 13(4): 211–214. (in Chinese)
- [30] 刘延,吴秋菊,舒清杰. 基于非成像高光谱的云烟97号叶片钾含量估算研究[J]. 山东农业科学,2018,50(4):138–141.
LIU Yan, WU Qiuju, SHU Qingtai. Estimation study on potassium content in Yunyan 97 leaves based on non-imaging hyperspectral data[J]. Shandong Agricultural Sciences, 2018, 50(4):138–141. (in Chinese)
- [31] ZHONG Ping, WANG Runsheng. Jointly learning the hybrid CRF and MLR model for simultaneous denoising and classification of hyperspectral imagery[J]. IEEE Transactions on Neural Networks and Learning Systems, 2014, 25(7): 1319–1334.
- [32] 刘炜,常庆瑞,郭曼,等. 土壤导数光谱小波去噪与有机质吸收特征提取[J]. 光谱学与光谱分析,2011,31(1):100–104.
LIU Wei, CHANG Qingrui, GUO Man, et al. Extraction of first derivative spectrum features of soil organic matter via wavelet de-noising[J]. Spectroscopy and Spectral Analysis, 2011, 31(1): 100–104. (in Chinese)
- [33] 梁亮,杨敏华,臧卓. 基于小波去噪与 SVR 的小麦冠层含氮率高光谱测定[J]. 农业工程学报,2010,26(12):248–253.
LIANG Liang, YANG Minhua, ZANG Zhuo. Determination of wheat canopy nitrogen content ratio by hyperspectral technology based on wavelet denoising and support vector regression[J]. Transactions of the CSAE, 2010, 26(12): 248–253. (in Chinese)
- [34] 张艳超,肖宇钊,庄载椿,等. 基于小波分解的油菜多光谱图像与深度图像数据融合方法[J]. 农业工程学报,2016, 32(16):143–150.
ZHANG Yanchao, XIAO Yuzhao, ZHUANG Zaichun, et al. Data fusion of multispectral and depth image for rape plant based on wavelet decomposition[J]. Transactions of the CSAE, 2016, 32(16): 143–150. (in Chinese)