

基于 CARS-CNN 的高光谱柑橘叶片含水率可视化研究

代秋芳^{1,2,3}, 廖巨龙^{1,2}, 李震^{1,2,3*}, 宋淑然^{1,2,3}, 薛秀云^{1,2,3}, 熊诗路^{1,2}

1. 华南农业大学电子工程学院(人工智能学院), 广东 广州 510642
2. 国家柑橘产业技术体系机械化研究室, 广东 广州 510642
3. 广东省农情信息监测工程技术研究中心, 广东 广州 510642

摘要 柑橘叶片水分亏缺是影响柑橘生长发育的重要因素之一,为研究水分胁迫对柑橘含水率的影响,利用高光谱快速无损检测柑橘叶片含水率,并应用伪彩色处理实现含水率可视化。收集100片柑橘叶片,使用烘干法得到鲜叶和烘干叶片一共500个不同梯度含水率的数据样本,将样本按7:3的比例划分为训练集(350个样本)和测试集(150个样本),使用决定系数(R^2)和均方根误差(RMSE)来评估模型预测的好坏。采用卷积神经网络(CNN)对高光谱数据进行预测,CNN模型使用一维卷积核,一共三层卷积池化层,使用RELU激活函数激活,输出层采用linear激活函数回归预测,使用nadam算法对模型进行优化更新,迭代次数为1000次;将原始光谱数据和SG, MSC和SNV三种预处理后的光谱数据,与全波段、CARS筛选的特征波段、PCA提取的特征波段组合,导入CNN模型,确定最佳模型为原始光谱数据的CARS-CNN,训练集的 R^2 和RMSEC分别为0.9679和0.0163,测试集的 R^2 和RMSEV分别为0.9470和0.0214;原始光谱数据的全波段CNN模型效果其次,训练集的 R^2 和RMSEC分别为0.9343和0.0249,测试集的 R^2 和RMSEV分别为0.9159和0.0286。对比了不同预处理方式和特征波长选择的支持向量机回归模型(SVR)、偏最小二乘法回归模型(PLSR)、随机森林模型(RF)组合的最佳结果,将最佳组合模型(原始光谱数据+CARS+PLSR, SNV+PCA+RF, SNV+PCA+SVR)与原始光谱数据的CARS-CNN对比,结果表明,依然是原始光谱数据的CARS-CNN模型预测效果最佳。相较于其他的模型,CARS-CNN模型经过CARS筛选特征波段和卷积核进一步提取特征后,预测精度远高于SVR, PLSR和RF模型。选择训练好的CARS-CNN模型,将高光谱图片导入到模型中,计算每个像素点的含水率,得到伪彩色图像,能够可视化叶片的含水率分布情况。研究结果为柑橘叶片水分含量提供了更快速、更直观、更全面的评估,为研究柑橘叶片水分胁迫提供了依据,为智能灌溉决策的优化提供了参考。

关键词 柑橘叶片; 含水率; 高光谱; 卷积神经网络; 可视化

中图分类号: O657.39 **文献标识码:** A **DOI:** 10.3964/j.issn.1000-0593(2022)09-2848-07

引言

水分是影响柑橘生长发育的主要因素之一。调亏灌溉(regulated deficit irrigation, RDI)是近年来发展起来的一种新型节水灌溉技术^[1]。RDI的作用是利用作物生长的特定阶段实施水分胁迫来调节光合作用产物在不同器官中的分布情况,防止其营养过盛并促进其生长。柑橘叶片是植株水分胁迫的最明显的特征之一,是光合作用最重要的地方,叶片含

水率会影响叶片的活性,进而影响果实的生长和产量。研究表明,在果实的抽梢开花期和幼果期应用轻度至中度亏水处理可显著提高作物的水分利用率,然而在柑橘果实膨大期应用亏水处理,会显著降低柑橘果实的产量。因此,检测柑橘叶片的含水率对于柑橘生长和水分利用是非常重要的^[2-4]。传统的作物水分测量方法有烘干法、蒸馏法等,虽然精度高,但是过程繁琐且测量时间长,对作物具有破坏性。高光谱成像技术可同时采集样品的空间及光谱信息,实现对样品的快速无损检测。Murphy等发现莴苣叶片与NDWI, MSI

收稿日期: 2021-07-28, 修订日期: 2021-10-26

基金项目: 国家自然科学基金项目(31971797), 广东省现代农业产业技术体系创新团队建设专项资金项目(2021KJ108), 财政部和农业农村部: 国家现代农业产业技术体系项目(CARS-26)资助

作者简介: 代秋芳, 女, 1979年生, 华南农业大学电子工程学院(人工智能学院)讲师 e-mail: daiqiu@scau.edu.cn

* 通讯作者 e-mail: lizhen@scau.edu.cn

和 IA 指数之间具有相关性，可以用于预测莴苣叶片的含水率^[5]。Zhen 利用偏最小二乘法结合特征波段提取的方法预测冬小麦叶片的含水率^[6]。

近几年，卷积神经网络(convolution neural network, CNN)由于具有权值共享和自动提取特征等优点，被广泛应用于生物学、食品学、医学等多个领域^[7-9]。钟亮利用不同的卷积神经网络模型预测土壤有机质，结果表明卷积神经网络在土壤高光谱样本建模中具备可行性^[10]。Jie 结合卷积神经网络测定柚子果实颗粒化，结果表明卷积神经网络模型可以有效提高分类的准确性^[11]。

本工作结合高光谱与卷积神经网络，研究柑橘叶片的含水率。首先利用烘干法测出柑橘叶片的含水率作为实际含水率，然后结合不同的预处理和特征波段选择的方法，将数据导入不同的检测模型中，得到最佳的预测模型。最后，将叶片所有像素导入到最佳的预测模型中，得到每个像素的含水率预测值，应用伪彩色处理实现柑橘叶片的含水率分布的可视化。

1 实验部分

1.1 柑橘叶片样本和样本含水率测定

2021 年 5 月，在华南农业大学工程学院六楼天台，在柑橘水分管理的关键时期随机均匀地摘取 100 片柑橘叶片；为了提高研究的泛化性和得到更多的不同含水率的叶片，摘取不同大小、营养状况和颜色的叶片，并立即将样品带回工程学院 302 实验室。使用电子天平测量每个叶片的质量记为 G_1 ，随后拍摄高光谱图像，然后使用恒温鼓风干燥箱在 50 °C 下烘干叶片，50 min 后取出放入装有干燥剂的密闭玻璃缸内冷却至室温，取出称其质量记为 G_2 ，再次拍摄高光谱图像，重复测量 5 次，每次烘干的温度和时间均为 50 °C 和 50 min，得到质量为 G_2 ， G_3 ， G_4 和 G_5 的叶片，最后再将叶片放入 85 °C 的干燥箱内烘干至恒重，恒重叶片记为 G_0 。柑橘叶片的含水率计算公式如式(1)所示。

$$M_n = \frac{G_n - G_0}{G_n} \times 100\% \quad (1)$$

式(1)中， M_n 为第 n 次测量的叶片含水率； G_n 为第 n 次测量的质量(g)； n 的取值为 1~5； G_0 为叶片干重(g)。对采集的叶片烘干 4 次，一共获得了鲜叶和烘干叶片 500 个样本。样本的含水率分布统计如表 1 所示，含水率在 19.59%~83.05%之间，平均值为 62.22%，方差为 0.93%。

表 1 柑橘叶片的含水率分布统计(%)

Table 1 Distribution statistics of water content in citrus leaves(%)

样本量	最小值	最大值	平均值	方差
500	19.59	83.05	62.22	0.93

1.2 高光谱数据采集

所有的样本均使用实验室的高光谱成像仪(HyperSIS Zolix, China)拍摄扫描，该仪器主要由 4 个卤光灯、CCD 相机(Gilden Photonics Ltd, UK)、样品移动台、计算机等组

成。成像仪的光谱波长范围为 369~988 nm，CCD 相机曝光时间设置为 8.96 ms，平台移动速度为 0.8 cm·s⁻¹，光谱分辨率为 1.2 nm。高光谱成像仪控制及图像校正软件为 SpectraVIEW。后续数据处理采用 ENVI5.3 软件，Anaconda 中的 Spyder，版本为 Python3.6。

为了减少光照和探测器灵敏度对原始高光谱图像的影响，在与柑橘叶片图像采集相同的实验条件下，通过拍摄白色校正图像和黑色校正图像对原始图像进行黑白校正。最终校正图像由式(2)所示。

$$R = \frac{I - B}{W - B} \quad (2)$$

式(2)中， R 为校正后的高光谱图像， I 为原始高光谱图像， W 为白色校正图像， B 为黑色校正图像。使用 ENVI5.3 软件提取整个柑橘叶片作为感兴趣区域，得到叶片的平均反射率值，一共 500 个样本×256 个波段，数据用于后续数据分析和建模。

不同含水率叶片的光谱曲线如图 1 所示。图 1(a)中为同一叶片在四次烘干后的不同含水率的光谱反射率，在其他条件不变的情况，每次烘干叶片的含水率逐次减少，含水率与光谱曲线成负相关变化趋势，这与前人研究的结果相一致；图 1(b)为不同叶片的含水率的光谱反射率，其中三个不同叶片的含水率均为 70%，但是光谱反射率却不尽相同，由于叶片的大小、颜色、营养状况等因素均会影响叶片的光谱反射率，因此不同叶片的含水率与光谱反射率并非呈简单的线性相关趋势。

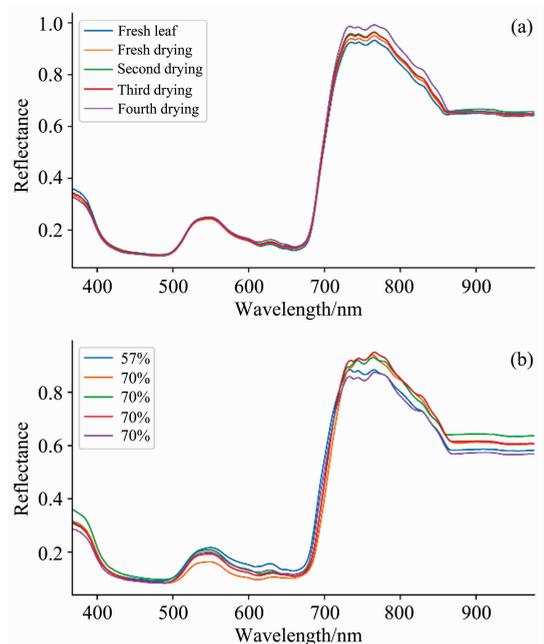


图 1 不同含水率叶片的光谱曲线

Fig. 1 Spectra of leaves with different moisture content

2 结果与讨论

2.1 光谱预处理

数据包括原始光谱数据和卷积平滑(savitzky golay,

SG)、多元散射校正(multiplicative scatter correction, MSC)、标准正态变量变换(standard normalized variate, SNV)3种预处理后的光谱数据。不同预处理后的光谱曲线如图 2 所示。

2.2 特征波段的选择

2.2.1 CARS 筛选特征波长

竞争性自适应重加权(competitive adaptive reweighted sampling, CARS)是基于蒙特卡罗采样和偏最小二乘回归(partial least squares regression, PLSR)模型中回归系数的一种特征波长选择方法^[12-13],旨在筛选最具有竞争力的波数组

合。CARS 算法通过自适应加权采样计算回归系数中绝对值权重,去掉权值较小的点,权值较大的点会作为新的子集,然后基于新的子集建立 PLSR 模型,选取交互验证均方根误差(root mean square error of cross validation, RMSECV)最小的 PLSR 模型所对应的波长作为特征波长。结果如图 3 所示,最终最佳迭代次数为 23 次,此时的 RMSECV 值最小,得到 493, 498, 508, 522, 589, 592, 601, 627, 635, 658, 678, 685, 736, 752, 788, 790, 826, 835, 845, 862, 874, 888, 914, 917, 938, 943, 962, 967 和 969 nm 共 29 个特征波段。

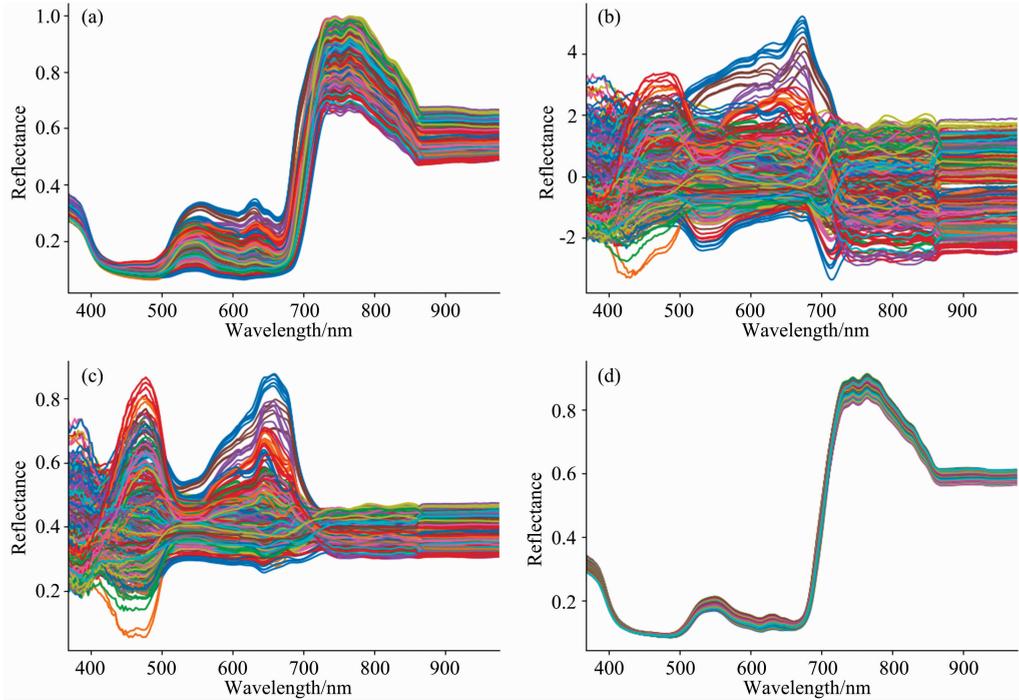


图 2 不同预处理后的光谱曲线

(a): 原始光谱; (b): SNV 预处理后光谱; (c): MSC 预处理后光谱; (d): SG 预处理后光谱

Fig. 2 Spectra after different pretreatments

(a): Raw spectra; (b): Pretreated by SNV; (c): Pretreated by MSC; (d): Pretreated by SG

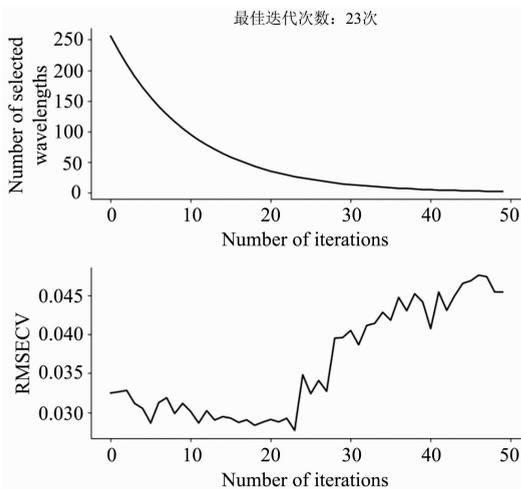


图 3 CARS 筛选特征波段

Fig. 3 CARS feature bands selection

2.2.2 PCA 提取特征波长

主成分分析(principle component analysis, PCA), PCA 是将多个变量通过线性变换转换为相互正交、信息不重叠的新变量^[14], PCA 概念简单、运算简洁,能够在保留有效信息的同时解决变量之间的多重共线性问题,在高光谱数据降维、特征提取、消除噪声、去相关性等方面得到广泛应用。采用 PCA 算法对全部样本的高光谱数据进行降维,前 10 个主成分(principle component, PC)累积贡献率达到 99.83%,因此选择前 10 个主成分。

2.3 模型

2.3.1 卷积神经网络

卷积神经网络是深度学习的典型模型之一,具有卷积计算和深度结构的前馈神经网络,基本结构由输入层、卷积层、激活层、池化层和全连接层组成。卷积层能够自动提取光谱样本的特征波段,卷积之后通常会加入偏置,并引入非线性激活函数,经过激活函数激活后,得到结果,如式(3)

所示

$$H_{x,y}^k = f((W^k \times X)_{x,y}) + b_k \quad (3)$$

式(3)中, X 为卷积层的输入矩阵, $H_{x,y}^k$ 为第 x 行、第 y 列卷积层的输出向量, W^k 为第 k 个卷积核的权重矩阵, b_k 为第 k 个卷积核的偏置向量, $f(\cdot)$ 是非线性激活函数, 由于高光谱数据是一维图像数据, 因此采用的卷积核为一维卷积核。池化是一种非线性的降采样方法, 对卷积层输出的特征值起到二次提取特征的作用, 能够对数据进行降维, 减少运算规模, 本研究采用最大池化法来对模型进行降采样处理。

2.3.2 模型建立

卷积神经网络模型的参数如表 2 所示, 模型一共采用三个卷积池化层, 卷积核的大小均设置为 1×3 , 步长为 1, 卷积核个数分别为 16, 32 和 64 个, 对于经过特征波段选择的光谱数据, 最大池化层设置为 1×1 , 步长为 1, 而全波段数据导入模型, 为了减少数据维度、提取有效特征, 最大池化层设置为 1×2 , 步长为 1。在每个卷积层设置一个线性整流 (rectified linear unit, RELU) 激活函数, 数据输入后, 经过三层卷积池化, 再将数据展开, 将得到的一维数据输入到全连接层, 全连接层有两个隐藏层, 隐含层 1 的神经元个数为 32 个, 激活函数设置为 RELU 函数, 隐含层 2 的神经元个数为

1 个, 激活函数设置为 linear, 用于回归预测。模型训练使用均方误差 (mean squared error, mse) 作为损失函数, 采用 nadam 算法对模型进行优化更新, epoch 设置为 1 000 轮, batch size 设置为 10。整个网络模型的基本架构如图 4 所示。

表 2 CNN 模型参数设置

Table 2 CNN model parameter setting

网络层	模型参数
输入层	全波段为 256×1 , CARS 筛选后为 29×1 , PCA 提取后为 10×1
卷积层 C1	卷积核大小为 $1 \times 3 \times 16$, 步长为 1
最大池化层 S1	最大池化, 步长为 1, 经过特征选择大小设置为 1×1 , 全波段大小设置为 1×2
卷积层 C2	卷积核大小为 $1 \times 3 \times 32$, 步长为 1
最大池化层 S2	最大池化, 步长为 1, 经过特征选择大小设置为 1×1 , 全波段大小设置为 1×2
卷积层 C3	卷积核大小为 $1 \times 3 \times 64$, 步长为 1
最大池化层 S3	最大池化, 步长为 1, 经过特征选择大小设置为 1×1 , 全波段大小设置为 1×2
全连接层 F5	32 个神经元
输出层	1 个神经元, 输出柑橘叶片含水量预测值

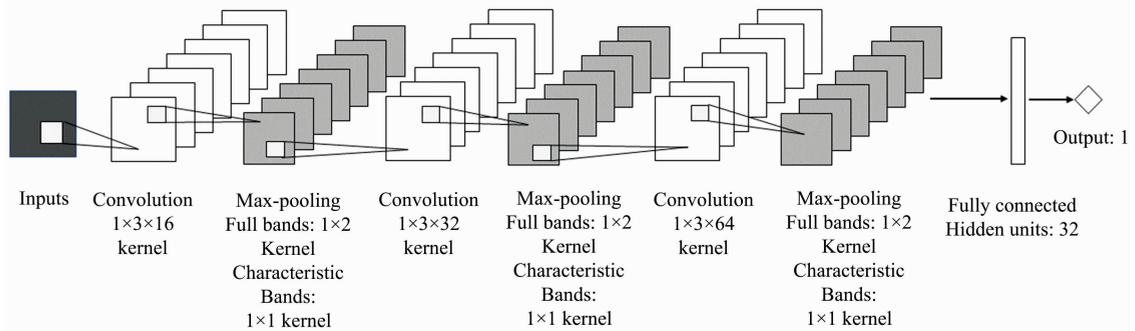


图 4 CNN 模型结构图

Fig. 4 CNN model structure diagram

将 500 个样本按 7 : 3 的比例划分成训练集和测试集。350 个样本被选为训练集, 150 个样本被选为测试集, 模型使用决定系数 (coefficient of determination, R^2) 和均方根误差 (root mean square error, RMSE) 来评估, R^2 越大、RMSE 越小, 则模型的预测效果越好。将原始数据和不同预处理后的光谱数据经过不同特征波段选择后导入到 CNN 模型中, 结果如表 3 所示。

结果表明原始光谱数据的 CARS-CNN 模型预测效果最佳, 训练集的 R^2 和 RMSEC 分别为 0.967 9 和 0.016 3, 测试集的 R^2 和 RMSEV 分别为 0.947 0 和 0.021 4。原始光谱数据 + 全波段 + CNN 模型预测效果其次, 训练集的 R^2 和 RMSEC 分别为 0.934 3 和 0.024 9, 测试集的 R^2 和 RMSEV 分别为 0.915 9 和 0.028 6。其余模型预测效果均不佳或存在过拟合现象。

2.3.3 不同模型比较

为了比较 CARS-CNN 模型的性能, 选择了 PLSR、随机森林 (random forest, RF)、支持向量机回归 (support vector

表 3 不同模型预测结果

Table 3 Forecast results of different models

模型	选择特征波段	数据预处理	训练集		测试集		
			R_p^2	RMSE	R_p^2	RMSE	
CNN	全波段	原始数据	0.934 3	0.024 9	0.915 9	0.028 6	
		SNV	0.998 6	0.003 5	0.876 1	0.034 0	
		MSC	0.964 8	0.017 5	0.866 2	0.037 7	
	PCA	原始数据	0.997 8	0.004 3	0.699 1	0.055 7	
		SNV	0.997 5	0.004 3	0.696 9	0.063 0	
		MSC	0.999 4	0.002 3	0.726 3	0.044 3	
	CARS	原始数据	0.999 7	0.001 4	0.169 6	0.104 7	
		原始数据	0.967 9	0.016 3	0.947 0	0.021 4	
		SNV	0.998 1	0.004 2	0.891 5	0.032 3	
			MSC	0.985 5	0.011 3	0.895 4	0.032 5
			SG	0.238 3	0.088 1	0.172 1	0.077 7

regression, SVR) 三种模型作为对比。将原始数据、SG、MSC、SNV, 全波段、PCA、CARS 算法与 PLSR、RF、SVR

模型组合,从 36 种组合算法中得到最优的预测结果与 CARS-CNN 模型作对比,结果如表 4 所示。4 种模型中, CNN 模型预测效果最佳,原始光谱数据+CARS+PLSR 效果其次,训练集的 R^2_c 和测试集的 R^2_p 达到了 0.879 4 和 0.858 1,尽管 SNV+PCA+RF 的训练集 R^2_c 达到 0.947 8,但是在测试集中 R^2_p 仅有 0.746 2,存在一定的过拟合现象,SNV+PCA+SVR 效果最差,训练集 R^2_c 和测试集 R^2_p 仅为 0.643 6 和 0.612 6。相较于传统机器学习,CARS-CNN 模型预测效果最佳, R^2_c 和 R^2_p 的预测结果分别比原始数据+CARS+PLSR 提升了 8.85% 和 8.89%,RMSEC 和 RMSEP 分别降低了 1.76% 和 1.33%,并且原始数据+全波段+CNN 模型预测效果依旧比机器学习好,无需对数据进行额外的处理。

图 5 分别为不同模型的训练集和测试集中的预测值和实际测量值的三点拟合图,其中蓝色的点代表训练集,红色的

点代表测试集,由图可以明显观察到 CARS-CNN 模型的拟合效果最佳,优于其他三个模型。而其他的三个模型均有明显的离散数据,SNV+PCA+SVR 最差,SVR 模型整体预测的误差相对较大,因此出现明显的偏移现象。

表 4 不同模型的预测效果对比

Table 4 Comparison of prediction results of different models

模型	训练集		测试集	
	R^2_c	RMSEC	R^2_p	RMSEC
原始数据+CARS+PLSR	0.879 4	0.033 9	0.858 1	0.034 7
SNV+PCA+RF	0.947 8	0.022 3	0.746 2	0.040 9
SNV+PCA+SVR	0.643 6	0.055 3	0.612 6	0.065 7
原始数据+CARS+CNN	0.967 9	0.016 3	0.947 0	0.021 4
原始数据+全波段+CNN	0.934 3	0.024 9	0.915 9	0.028 6

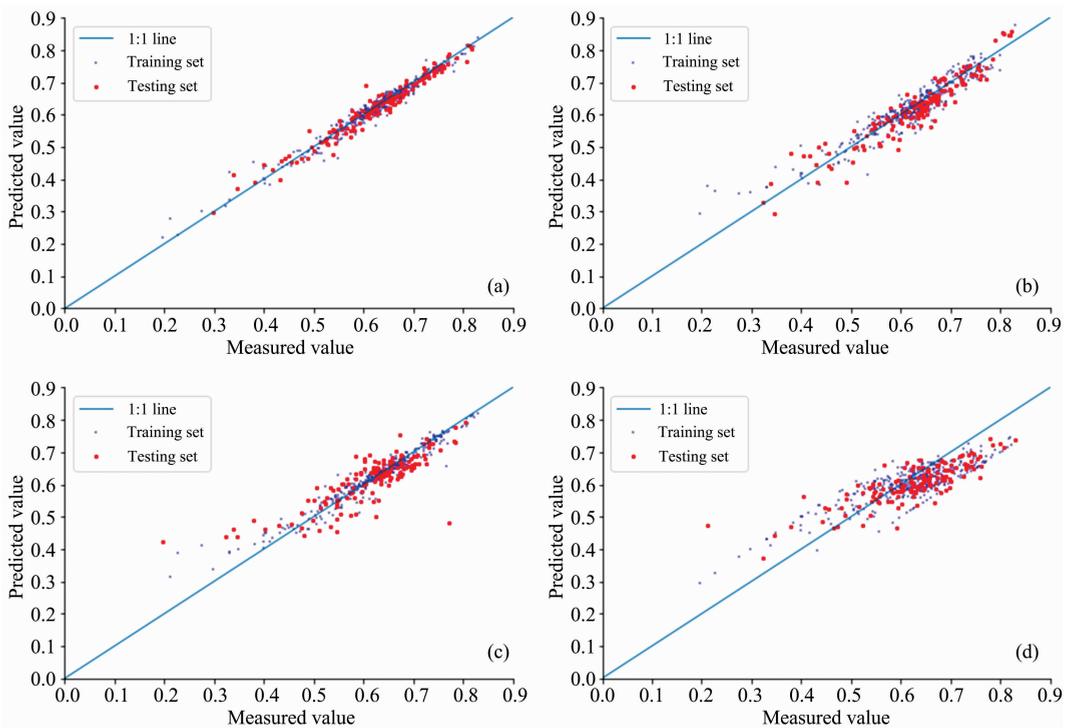


图 5 不同模型回归曲线图

(a): 原始数据+CARS+CNN; (b): 原始数据+CARS+PLSR; (c): SNV+PCA+RF; (d): SNV+PCA+SVR

Fig. 5 Regression curves of different models

(a): Raw spectra+CARS+CNN; (b): Raw spectra+CARS+PLSR; (c): SNV+PCA+RF; (d): SNV+PCA+SVR

2.4 柑橘叶片含水率可视化

每个叶片样本仅使用对应感兴趣区域提取的平均光谱表示,然而高光谱图像中存在丰富的空间分布信息未被充分研究。因此本研究中利用最佳模型 CARS-CNN 预测高光谱图像中各个像素点的含水率,以实现其分布可视化。首先通过 ENVI5.3 软件去除叶片的背景,将提取叶片的光谱反射率值导入到训练好的 CARS-CNN 模型中,得到每个像素的含水率预测值,转换为灰度图,再应用伪彩色技术将灰度图转为伪彩色图。柑橘叶片的不同含水率分布图如图 6 所示。

图 6 从左到右的含水率分别为 81%, 63%, 42% 和 19%。从图中可以看到,含水率越高,叶片图像素越接近红色,含水率越低,叶片图像素越接近蓝色。柑橘叶片水分分布图的可视化为每个像素的水分含量提供了更直观、更全面的评估,并提供了一种评估植物灌溉策略优劣的新方法。

3 结论

(1) 采用原始光谱数据和 SG, MSC 和 SNV 三种预处理,

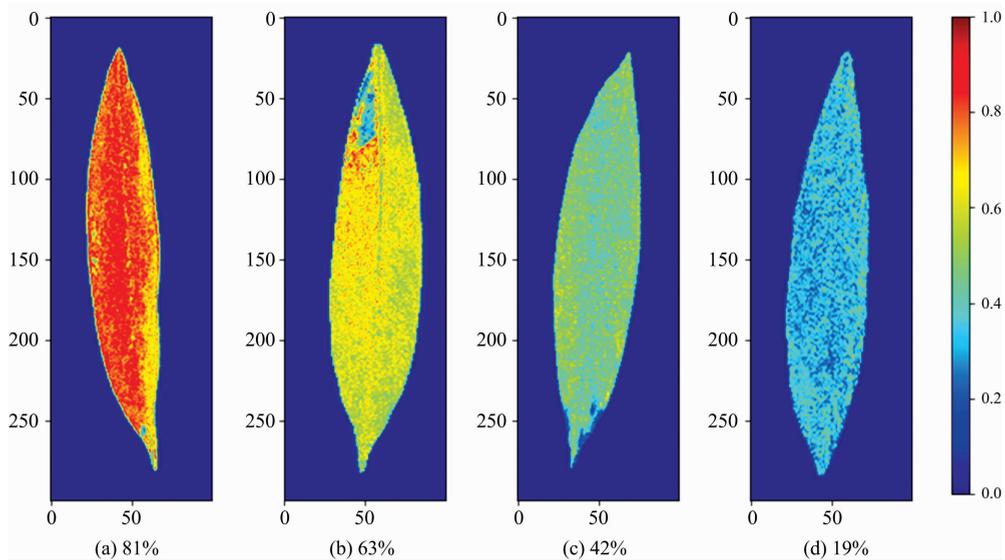


图6 不同含水率分布图

Fig. 6 Distribution maps of different moisture contents

与全波段、CARS 筛选特征波段、PCA 提取特征波段导入 CNN 模型, 结果表明 CARS-CNN 模型预测效果最佳, 训练集的 R^2 和 RMSEC 分别为 0.967 9 和 0.016 3, 测试集的 R^2 和 RMSEV 分别为 0.947 0 和 0.021 4。原始光谱数据+全波段+CNN 模型预测效果其次, 训练集的 R^2 和 RMSEC 分别为 0.934 3 和 0.024 9, 测试集的 R^2 和 RMSEV 分别为 0.915 9 和 0.028 6;

(2) 同时对比了不同预处理和特征波长提取选择的 PLSR, RF 和 SVR 模型组合的最佳结果, 将最佳组合模型(原始光谱数据+CARS+PLSR, NV+PCA+RF, SNV+PCA+SVR)与原始光谱数据的 CARS-CNN 对比, 结果依然

是 CARS-CNN 模型预测效果最佳;

(3) 使用训练好的 CNN 模型计算叶片每个像素点的含水率, 得到 81%, 63%, 42% 和 19% 不同梯度的含水率伪彩色图, 为检测和评估柑橘生长和叶片含水率提供了一种全新的方法。

(4) 在其他条件不变的情况下, 同一叶片的含水率与光谱反射率呈负相关趋势, 而在自然条件下, 由于叶片的光谱反射率受叶片的大小、颜色、营养状况、种类等多种因素的影响, 叶片的含水率与其他因素会共同影响叶片的光谱反射率, 因此叶片的含水率与光谱反射率并非呈简单的线性关系, 具体的因素仍需进一步研究。

References

- [1] CHEN Fei, LI Hong-ping, CUI Ning-bo(陈飞, 李鸿平, 崔宁博). Agricultural Research in the Arid Areas(干旱地区农业研究), 2021, 39(3): 42.
- [2] LI Hong-ping, CUI Ning-bo, CHEN Yu-xin(李鸿平, 崔宁博, 陈昱辛). Journal of Irrigation and Drainage(灌溉排水学报), 2019, 38(10): 1.
- [3] ZHANG Xiao-xing, FAN Yi, JIA Yue, et al(张效星, 樊毅, 贾悦, 等). Transactions of the Chinese Society of Agricultural Engineering(农业工程学报), 2018, 34(3): 143.
- [4] Panigrahi P, Srivastava A K. Scientia Horticulturae, 2016, 210: 6.
- [5] Murphy R J, Whelan B, Chlingaryan A, et al. Precision Agriculture, 2018, 20: 767.
- [6] Zhu Zhen, Li Tiansheng, Cui Jing, et al. Acta Agriculturae Scandinavica, Section B—Soil & Plant Science, 2020, doi:10.1080/09064710.2020.1726999.
- [7] Malek Salim, Melgani Farid, Bazi Yakoub. Journal of Chemometrics, 2018, 32(5): e2977.
- [8] Dong Jialin, Hong Mingjian, Xu Yi, et al. Journal of Chemometrics, 2019, 33: e3184.
- [9] Acquarelli J, Van Laarhoven T, Gerretzen J, et al. Analytica Chimica Acta, 2017, 954: 22.
- [10] ZHONG Liang, GUO Xi, GUO Jia-xin, et al(钟亮, 郭熙, 郭佳欣, 等). Transactions of the Chinese Society of Agricultural Engineering(农业工程学报), 2021, 37(1): 203.
- [11] Jie Dengfei, Wu Shuang, Wang Ping, et al. Food Analytical Methods, 2021, 14: 280.
- [12] Song Xiangzhong, Du Guorong, Li Qianqian, et al. Analytical and Bioanalytical Chemistry, 2020, 412: 2795.

[13] Kumar Keshav. *Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy*, 2021, 244: 118874.

[14] Guerra-Urzola R, Van Deun K, Vera J C, et al. *Psychometrika*, 2021, 86(4): 893.

Hyperspectral Visualization of Citrus Leaf Moisture Content Based on CARS-CNN

DAI Qiu-fang^{1, 2, 3}, LIAO Chen-long^{1, 2}, LI Zhen^{1, 2, 3*}, SONG Shu-ran^{1, 2, 3}, XUE Xiu-yun^{1, 2, 3}, XIONG Shi-lu^{1, 2}

1. College of Electronic Engineering (College of Artificial Intelligence), South China Agricultural University, Guangzhou 510642, China

2. Division of Citrus Machinery, China Agriculture Research System, Guangzhou 510642, China

3. Information Monitoring Engineering Technology Research Center, Guangzhou 510642, China

Abstract Water deficit of citrus leaves is one of the important factors affecting the growth of citrus. In order to study the effect of water stress on the moisture content of citrus, hyperspectral technology was used to rapidly and non-destructively detect the moisture content of citrus leaves, and pseudo-color processing was applied to realize the visualization of moisture content. 100 citrus leaves were collected, and 500 leaves with different gradient moisture content were obtained by drying method. The samples were divided into a training set (350 samples) and a testing set (150 samples) according to the ratio of 7 : 3. The determination coefficient (R^2) and root mean square error (RMSE) was used to evaluate the model's prediction quality. A convolution neural network (CNN) is used to predict spectrum data. The CNN model uses a one-dimensional convolution kernel with three convolution pooling layers activated by the RELU activation function. The output layer uses a linear activation function for regression prediction, and the nadam algorithm is used to optimize and update the model with 1 000 epochs; The Raw spectrum data and the spectrum data are pretreated by SG, MSC and SNV are used respectively. The full bands, the feature bands screened by CARS and the feature bands extracted by PCA are imported into the CNN model respectively. The best model is CARS-CNN of the Raw spectrum data, the R_c^2 and RMSEC of the training set are 0.967 9 and 0.016 3 respectively. The R_v^2 and RMSEV of the testing set are 0.947 0 and 0.021 4, respectively. The effect of the full bands CNN model of the Raw spectrum data is the second, and the R_c^2 and RMSEC of the training set are 0.934 3 and 0.024 9, respectively. The R_v^2 and RMSEV of the testing set are 0.915 9 and 0.028 6, respectively; At the same time, the best combined results of the support vector machine regression model (SVR), partial least squares regression model (PLSR) and random forest model (RF) under different pretreatment methods and characteristic wavelength selection were compared. The best combination model (Raw spectrum+CARS+PLSR, SNV+PCA+RF, SNV+PCA+SVR) was compared with CARS-CNN of Raw spectrum data, CARS-CNN model still has the best prediction effect. Compared with other models, the CARS-CNN model has higher prediction accuracy than SVR, PLSR and RF models, after further feature extraction by CARS and convolution kernel. Select the trained CARS-CNN model, import the hyperspectral image into the model, calculate the moisture content of each pixel, and get the pseudo-color image, which can more intuitively display the visual distribution of leaf moisture content. The result provides a faster, more intuitive and more comprehensive assessment of citrus leaf moisture content, a basis for the study of citrus leaf water stress, and a reference for optimising intelligent irrigation decision-making.

Keywords Citrus leaf; Moisture content; Hyperspectral; Convolution neural network; Visualization

(Received Jul. 28, 2021; accepted Oct. 26, 2021)

* Corresponding author