doi:10.6041/j.issn.1000-1298.2025.05.036

去除土壤背景影响的多光谱遥感影像玉米叶面积指数估算

付新阳[1]　崔利华[1]　董雨昕[1]　韩文霆[1,2]

(1.西北农林科技大学机械与电子工程学院,陕西杨凌 712100;2.西北农林科技大学旱区节水农业研究院,陕西杨凌 712100)

摘要:土壤背景对玉米叶面积指数(Leaf area index, LAI)的准确估算存在影响,传统土壤背景去除方法由于消除了土壤像素的面积信息从而导致目标区域光谱与玉米 LAI 的相关性降低。因此,本文提出了一种土壤背景去除方法,该方法在去除土壤像素光谱反射率的同时保留了土壤像素面积信息,基于该方法对多光谱影像进行预处理并提取归一化差异植被指数(Normalized difference vegetation index, NDVI)等 26 个植被指数与 Mean 等 8 个纹理特征,结合株高/叶绿素含量等作物长势协变量,对以上 3 种不同类型的特征进行排列组合形成多个输入特征集合,利用 8 种建模算法建立多个 LAI 估算模型,并与基于传统土壤背景去除方法的 LAI 估算模型进行对比。结果表明,本文提出的土壤背景去除方法在保留土壤像素和植被像素面积信息的前提下有效消除了土壤光谱反射率对植被光谱反射率的影响,基于该方法建立的 LAI 估算模型效果均优于传统方法;多类型特征融合可提高多光谱影像对 LAI 的模型估算精度,纹理特征对 LAI 的估算效果优于植被指数;机器学习模型对 LAI 的模型估算效果优于传统统计回归算法,最优模型是经本文所提土壤背景处理方法预处理后以植被指数 + 纹理特征 + 株高/叶绿素含量作为输入的一维卷积神经网络(One-dimensional convolutional neural network, 1D - CNN)模型,其测试集调整决定系数 R^2_{Adj}、均方根误差(RMSE)和平均绝对误差(MAE)分别为 0.951 5、0.242 1 和 0.179 5。研究结果可为快速、准确估算玉米 LAI 提供方法。

关键词:玉米;叶面积指数;多光谱遥感;土壤背景去除;机器学习

中图分类号:S127　　**文献标识码**:A　　**文章编号**:1000-1298(2025)05-0384-11　　**OSID**:

Estimation of Maize Leaf Area Index From Multi-spectral Remote Sensing with Soil Background Effects Removed

FU Xinyang[1]　CUI Lihua[1]　DONG Yuxin[1]　HAN Wenting[1,2]

(1. *College of Mechanical and Electronic Engineering, Northwest A&F University, Yangling, Shaanxi* 712100, *China*
2. *Research Institute of Water-saving Agriculture in Dry Areas, Northwest A&F University, Yangling, Shaanxi* 712100, *China*)

Abstract: Soil background has an impact on the accurate estimation of maize leaf area index(LAI), and the traditional soil background removal method eliminates the area information of soil pixels thus resulting in a lower correlation between the target area spectrum and maize LAI. Therefore, a soil background removal method was proposed, which removed the spectral reflectance of soil pixels while retaining the area information of soil pixels. Based on this method, the multispectral image was preprocessed and 26 vegetation indices such as normalized difference vegetation index (NDVI) were extracted along with eight texture features such as Mean. Combined with crop growth covariates such as plant height/chlorophyll content, the above three different types of features were arranged and combined to form multiple input feature sets, and eight modeling algorithms were used to build multiple LAI estimation models, which were compared with those based on traditional soil background removal methods. The results showed that the soil background removal method proposed effectively eliminated the effect of soil spectral reflectance on vegetation spectral reflectance under the premise of retaining the area information of soil pixels and vegetation pixels, and the LAI estimation models based on this method were better than the traditional methods; the fusion of multiple types of features can improve the model estimation accuracy of LAI from multispectral images, and the estimation effect of texture features on LAI was better than that of the vegetation index; the machine learning model was better than the traditional statistical regression

收稿日期:2024 - 12 - 15　修回日期:2025 - 01 - 11

基金项目:国家重点研发计划项目(2022YFD1900802)

作者简介:付新阳(1999—),男,硕士生,主要从事无人机遥感数据实时处理系统研究,E-mail:fu.x.y@nwafu.edu.cn

通信作者:韩文霆(1972—),男,研究员,博士,主要从事农情信息空天地一体化智能感知技术及装备研究,E-mail:hanwt2000@126.com

algorithm for LAI estimation, and the optimal model was the one-dimensional convolutional neural network (1D－CNN) model with vegetation index + texture features + plant height/chlorophyll content as inputs, which was pre-processed with the soil background processing method proposed. 1D－CNN model with testing set adjust coefficient of determination R^2_{Adj}, root mean square error (RMSE), and mean absolute error (MAE) of 0.951 5, 0.242 1, and 0.179 5, respectively. The research result may provide a method for rapid and accurate estimation of maize LAI.

Key words: maize; leaf area index; multi-spectral remote sensing; soil background remove; machine learning

0　引言

玉米是我国重要的粮食和饲料作物之一，其对于保障我国粮食安全具有重要意义，因此，及时、准确地监测玉米长势至关重要[1]。叶面积指数(Leaf area index, LAI)是单位土地面积上植物单面叶片面积总和占土地面积的比例[2]。LAI 与植被密度、单复层结构、生物学特征和环境条件等均存在密切关系，是表征植被光能利用情况和冠层结构的有效指标，在监测玉米长势方面得到了广泛应用。

在遥感估计方法中[3]，作物叶片在不同光谱范围的吸收和反射特性不同，如在可见光范围表现出较强的吸收特性，在近红外范围反射特性则表现更加明显，为作物农情信息的遥感监测提供了理论基础。因此在农业方面，无人机遥感被广泛用于水分胁迫[4]、杂草和病原检测[5]，营养状况[6]和长势评估[7]，产量预测[8]等方面。

利用遥感估测 LAI 的研究表明作物冠层光谱特征随着其背景光学特性的变化而产生较大差异[9]。土壤背景严重影响玉米 LAI 估算精度，光谱多样性指标容易受到逐像素土壤信息的影响，显著增加局部光谱异质性[10]。传统的土壤背景去除方法是基于 NDVI 的阈值法[11]，通过设定阈值得到 NDVI 的二值化掩膜图像，利用该图像对原始图像进行掩膜，消除土壤像素，然而，这种直接将土壤像素消除的方法未能保留土壤像素的面积信息，而土壤与植被面积信息对于 LAI 的表征至关重要。借鉴线性光谱混合分析(Linear spectral mixture analysis, LSMA)概念建立的 LAI 估算模型对叶片叶绿素含量和土壤背景均不敏感[12]，但 LAI 与多种植被指数特征之间均存在一定的相关性，仅基于 RSARE 一种指数对 LAI 估算的精度有限。通过引入定量方法来考虑土壤信息的贡献度，进而对植被指数进行校正，基于校正后的植被指数建立玉米 LAI 估算模型[13]，与直接去除土壤像素相比，该方法可有效减少土壤对玉米 LAI 估算的影响，然而，植被指数是由一个或多个单波段反射率进行线性或非线性运算得到，在此过程中土壤对植被指数的贡献度可能会产生变化，且其所使用的土壤像素比例因子为整幅图像的平均值，未考虑空间差异性带来的影响。

另一方面，将物理模型与统计方法相结合来估算作物 LAI，估算精度为 $R^2=0.939$，归一化均方根误差(NRMSE)为 6.474%[14]。将局部二值化和方差特征求得的纹理信息与基于植被指数(Vegetation index，VI)的光谱信息相结合来估计水稻 LAI，光谱和纹理特征组合表现出比 VI 更好的预测能力[15]。从图像信息中提取 3 个形态参数和 2 个植被指数用于建立玉米不同生育期的 LAI 估计模型，图像信息和光谱信息融合可提高作物 LAI 的估计精度[16]。利用从 RGB 图像中提取的颜色指数和纹理特征来估算冬小麦 LAI，LAI 与颜色特征表现出明显正相关，与纹理特征表现出明显负相关[17]。结合植被指数、纹理特征与颜色特征估算冬小麦 LAI，相对于考虑单一类型变量，多类型变量结合时的模型精度更高，纹理特征和颜色特征可有效改善植被指数在高密度层次下的饱和问题[18]。因此，特征类型的增加可提高 LAI 估算模型的精度。

因此，为从根本上去除土壤背景光谱反射率对植被光谱的影响，并保留土壤与植被的面积信息，提高目标区域光谱与 LAI 的相关性，进而提高光谱对玉米 LAI 的估算精度，本文提出一种土壤背景去除方法，并以玉米为研究对象，以多光谱遥感为监测手段，利用本文所提土壤背景去除方法对多光谱遥感影像进行预处理并提取特征，将 3 种不同特征类型(植被指数、纹理特征、株高/叶绿素含量)通过不同的排列组合形成多组输入特征集合，结合多种统计回归或机器学习算法建立多个 LAI 估算模型，并将基于本文所提土壤背景去除方式下不同输入特征和不同算法的模型精度与传统土壤背景去除方式下的模型精度进行对比，以期证明该土壤背景去除方法的有效性。

1　数据获取与方法

本文整体技术路线如图 1 所示。

1.1　研究区概况

实验于 2023 年 5—9 月在内蒙古自治区巴彦淖

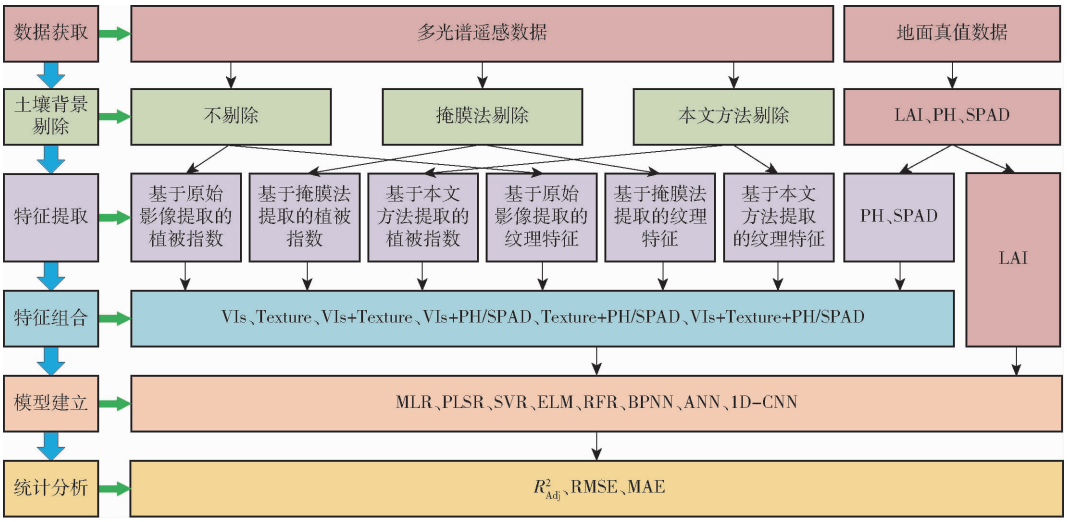

图 1 技术路线图

Fig. 1 Technology roadmap

尔市杭锦后旗头道桥镇黄河村(40°30′40″N,107°07′20″E)进行,该区域属于典型温带大陆性气候,多年平均气温 8℃,1 月平均气温 -22.1℃,7 月平均气温 37.8℃,无霜期平均 135 d,年平均日照时数 3 254 h,其地理位置如图 2a 所示。

实验研究对象为糯玉米,玉米品种有“万糯 2000”、“万糯 2018”和“万糯 8 号”,采用宽窄行形式播种,其中宽行行距为 80 cm,窄行行距为 40 cm,株距为 20 cm。实验田面积为 3.44 hm^2,如图 2b 所示。将实验田分为 12 个地块,每个地块细分为 3 个重复小区。采用五点取样法,在每个地块内标记出 5 个 2 m×2 m 的采样区用于采集地面数据,共计 60 个采样区,其中滴灌采样区 45 个,畦灌采样区 15 个。施水梯度设计均以无水分胁迫条件下(以田间持水量的 90% 作为无水分胁迫状态)的玉米需水量为基准[19],在此基础上设置需水量的不同百分比作

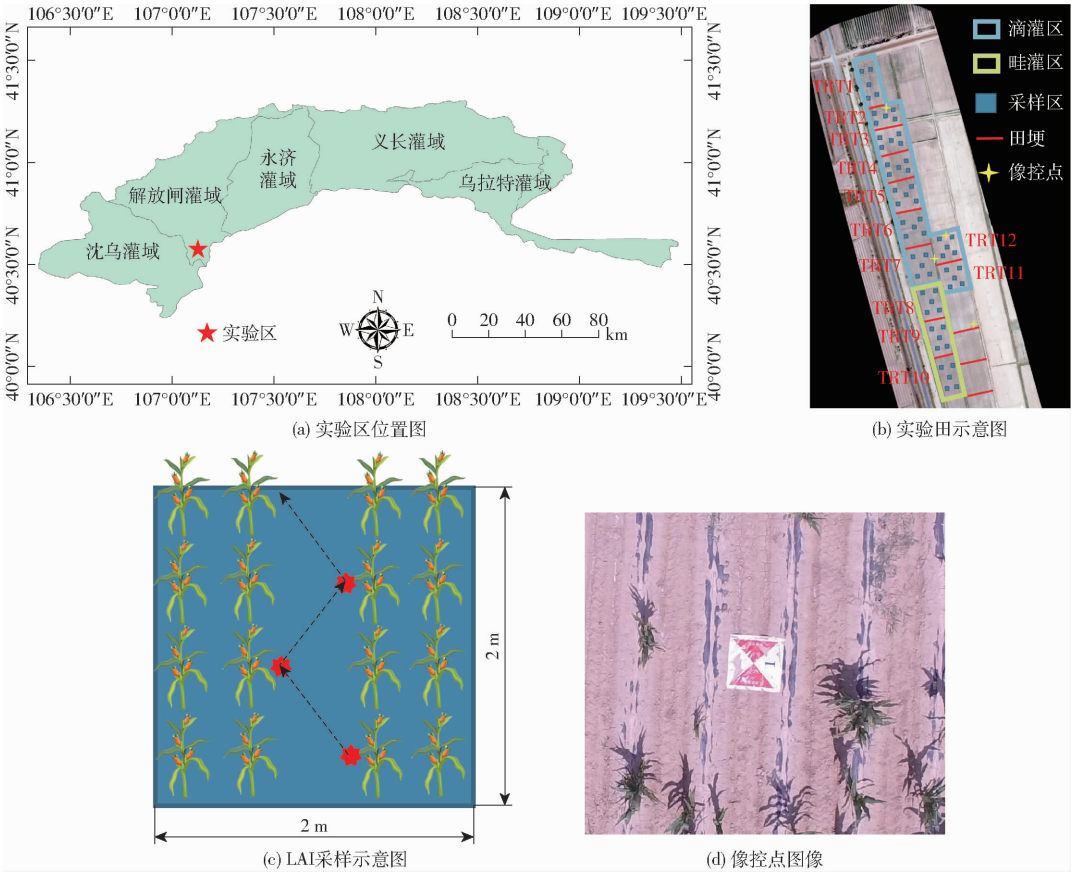

图 2 实验区地理位置概况

Fig. 2 Geographic location of experimental area

为胁迫区域计划施水量。施肥梯度设计以氮肥作为控制对象，施氮量分为 3 个梯度：300.0、225.0、112.5 kg/hm^2。施水施肥梯度如表 1 所示。其中，TRTi(i=1,2,…,12)表示第 i 个处理区。

表 1　施水施肥梯度设计

Tab.1　Water and fertilizer gradient design

灌溉方式	水胁迫水平	肥胁迫水平		
		300.0 kg/hm^2	225.0 kg/hm^2	112.5 kg/hm^2
滴灌	100%	TRT1	TRT2	TRT3
	75%	TRT4	TRT5	TRT6
	50%	TRT7	TRT11	TRT12
畦灌	100%	TRT8	TRT9	TRT10

1.2　数据获取与预处理

1.2.1　地面数据采集

在实验地玉米生育期内共采集 5 轮 LAI(6 月 15 日、7 月 28 日、8 月 5 日、8 月 19 日、8 月 24 日)。LAI 利用 LAI-2200C 型冠层分析仪(LICOR,美国)进行测量，每个采样区以“Z”字形选取 3 个位置进行测量，如图 2c 所示，确保可对采样区进行全覆盖，3 个位置 LAI 取平均后作为该采样区 LAI。在采样区内随机选取 3 株玉米，选择其第 2 或第 3 展开叶用 SPAD-502 Plus 型便携式叶绿素仪采集玉米的 SPAD 值作为玉米叶绿素含量参考值，测量 3 次取平均作为该植株 SPAD 值，最后取 3 个植株 SPAD 平均值作为该采样区 SPAD 值。同样地，株高利用塔尺进行测量，测量时在采样区内随机选取 3 株玉米，测量其自然状态下的最高点到地面的距离，取平均后作为该采样区株高(Plant height, PH)。

1.2.2　无人机数据采集

使用 DJI Matrice600 Pro 型无人机搭载 RedEdge-M 型多光谱相机采集多光谱影像。实验期间，在晴朗无云天气下进行无人机遥感影像采集，采集时间段为北京时间 11:00—14:00，飞行高度为 70 m，飞行速度为 6.6 m/s，多光谱遥感影像地面分辨率为 4.2 cm。为保证遥感影像拼图质量，无人机航线航向和旁向重叠率均设置为 90%。采用 1 m×1 m 的像控布进行像控点布设，像控点位置及其图像分别如图 2b、2d 所示。

1.3　土壤背景剔除方法

传统的土壤背景剔除方法利用目视解译结合阈值法得到二值化土壤掩膜图像(植被像素值为 1，土壤像素值为 0)，利用土壤掩膜图像对原始图像进行掩膜，使植被像素值保持不变，土壤像素设为 No data，不参与后续特征提取和运算，得到经过掩膜处理的图像；本文提出的土壤背景去除方法通过将土壤掩膜图像与原始图像进行按像素相乘，使植被像素值保持不变，土壤像素值全部置为零，得到经过土壤背景剔除的图像。2 种方法原理图如图 3 所示。

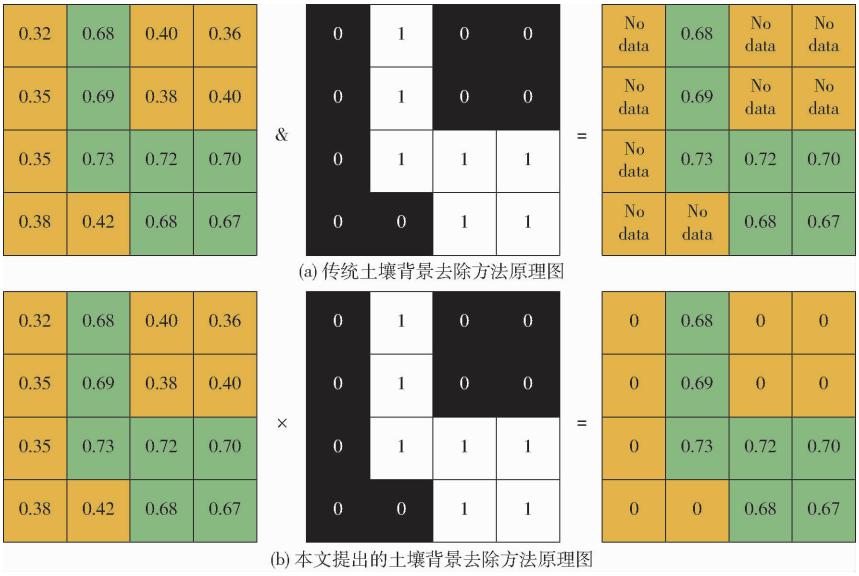

图 3　不同土壤背景去除方法原理图

Fig.3　Principles figure of different soil pixel treatment methods

1.4　植被指数与纹理特征提取

选取常用的 26 个植被指数和 8 个纹理特征作为模型输入。

利用 ENVI 5.3 的感兴趣区域(Region of interest, ROI)提取工具分别提取光谱影像不同波段的原始反射率图像、经过传统掩膜法处理的反射率图像和经过本文所提出的方法处理的反射率图像的平均反射率，利用 Matlab R2022b 计算所需的植被指数，包括：归一化差异植被指数(Normalized difference vegetation index, NDVI)[20]、改进简单比值植被指数(Modified simple ratio, MSR)[21]、差值植被指数(Difference vegetation index, DVI)[21]、调

整差值植被指数(Renormalized difference vegetation index, RDVI)[21]、土壤调节植被指数(Soil adjusted vegetation index, SAVI)[21]、增强植被指数(Enhanced vegetation index, EVI)[21]、增强植被指数2(Enhanced vegetation index 2, EVI2)[21]、改良土壤调整植被指数(Modified soil adjustment vegetation index, MSAVI)[21]、转换土壤调整植被指数(Transformed soil adjusted vegetation index, TSAVI)[21]、经调整的转换土壤调整植被指数(Adjusted-transformed soil adjusted vegetation index, ATSAVI)[21]、修正三角植被指数(Modified triangular vegetation index, MTVI)[21]、三角植被指数(Triangle vegetation index, TVI)[21]、优化土壤调节植被指数(Optimization of soil regulatory vegetation index, OSAVI)[21]、大动态范围植被指数(Wide dynamic range vegetation index, WDRVI)[21]、改进非线性植被指数(Modified nonlinear vegetation index, MNLI)[21]、结构不敏感色素植被指数(Structure-independent pigment index, SIPI)[22]、比值植被指数(Ratio vegetation index, RVI)[23]、植被衰老反射率指数(Plant senescence reflectance index, PSRI)[24]、红边叶绿素植被指数(Red edge chlorophyll index, RECI)[25]、修正三角植被指数2(Modified triangular vegetation index 2, MTVI2)[26]、绿色归一化差异植被指数(Green normalized difference vegetation index, GNDVI)[27]、蓝色归一化植被指数(Blue normalized difference vegetation index, BNDVI)[27]、转换叶绿素吸收指数(Transform chlorophyll absorption index, TCARI)[28]、绿色叶绿素植被指数(Green coverage index, GCI)[29]、归一化差异红边植被指数(Normalized difference red edge index, NDRE)[30]和核归一化差值植被指数(kernel Normalized difference vegetation index, kNDVI)[31]。

同样地,利用 ENVI 5.3 纹理特征提取工具分别提取以上 3 种图像均值、方差、同质度、对比度、非相似性、熵、角二阶矩和相关性等 8 种纹理特征,分析窗口尺寸为 3×3,计算方向为 45°。

对提取的特征和作物长势协变量进行排列组合,最终共形成 60 组模型输入特征集合。

1.5 模型构建

选取多元线性回归(Multiple linear regression, MLR)、偏最小二乘回归(Partial least squares regression, PLSR)、支持向量回归(Support vector regression, SVR)、极限学习机(Extreme learning machine, ELM)、随机森林回归(Random forest regression, RFR)、BP 神经网络(BP neural network, BPNN)、人工神经网络(Artificial neural networks, ANN)和一维卷积神经网络(One-dimensional convolutional neural network, 1D-CNN)等算法结合不同的输入特征集合分别建立 LAI 估算模型,最终共得到 480 个 LAI 估算模型,并对模型结果进行了比较。其中,SVR 算法核函数选择 RBF 核,其超参数(惩罚系数 C 和核函数系数 g)和随机森林算法的超参数(决策树数量、最小叶子数)均利用网格寻优法进行最优值提取;ELM、BPNN 和 ANN 隐藏层神经元个数大致范围确定公式为

$$N_h = \frac{N_s}{\alpha(N_i + N_o)}$$

式中 N_h——神经元数量

N_s——训练集样本数量

N_i——输入层神经元数量

N_o——输出层神经元数量

α——经验值,通常取 2~10

并结合经验进行微调得到最终结果;1D-CNN 算法的卷积核采用较为常用的 3×1 卷积核。所有数据分析与建模操作均在 Matlab R2022b 软件中实现。

1.6 评价指标

采用调整决定系数(Adjust coefficient of determination, R^2_{Adj})、均方根误差(Root mean square error, RMSE)和平均绝对误差(Mean absolute error, MAE)作为模型精度评价指标。

2 结果与讨论

2.1 结果

2.1.1 不同土壤背景去除方法对 LAI 估算模型精度的影响

对由不同土壤背景去除方法下得到的多个模型的效果进行统计并绘制对应的箱型图如图 4 所示。其中,由原始图像(origin)得到的植被指数/纹理特征及其组合、由经掩膜法(mask)处理后的图像得到的植被指数/纹理特征及其组合、由经本文所提方法(zero)处理后的图像得到的植被指数/纹理特征及其组合的调整决定系数 R^2_{Adj} 均值分别为:训练集 0.926 0(范围:0.827 2~0.988 3)、0.908 2(范围:0.758 8~0.975 2)、0.934 7(范围:0.865 0~0.979 3),测试集 0.863 6(范围:0.753 4~0.913 6)、0.843 9(范围:0.734 2~0.919 7)、0.883 0(范围:0.765 3~0.951 5)。由本文所提方法得到的模型效果最好,且其箱型图体积最小,说明模型效果的方差最小,模型变化范围最小,模型效果相对更加稳定(训练集 RMSE 为 0.133 6~0.341 7,MAE 为 0.101 0~0.268 8;测试集 RMSE 为 0.221 8~0.403 6,MAE 为 0.163 1~

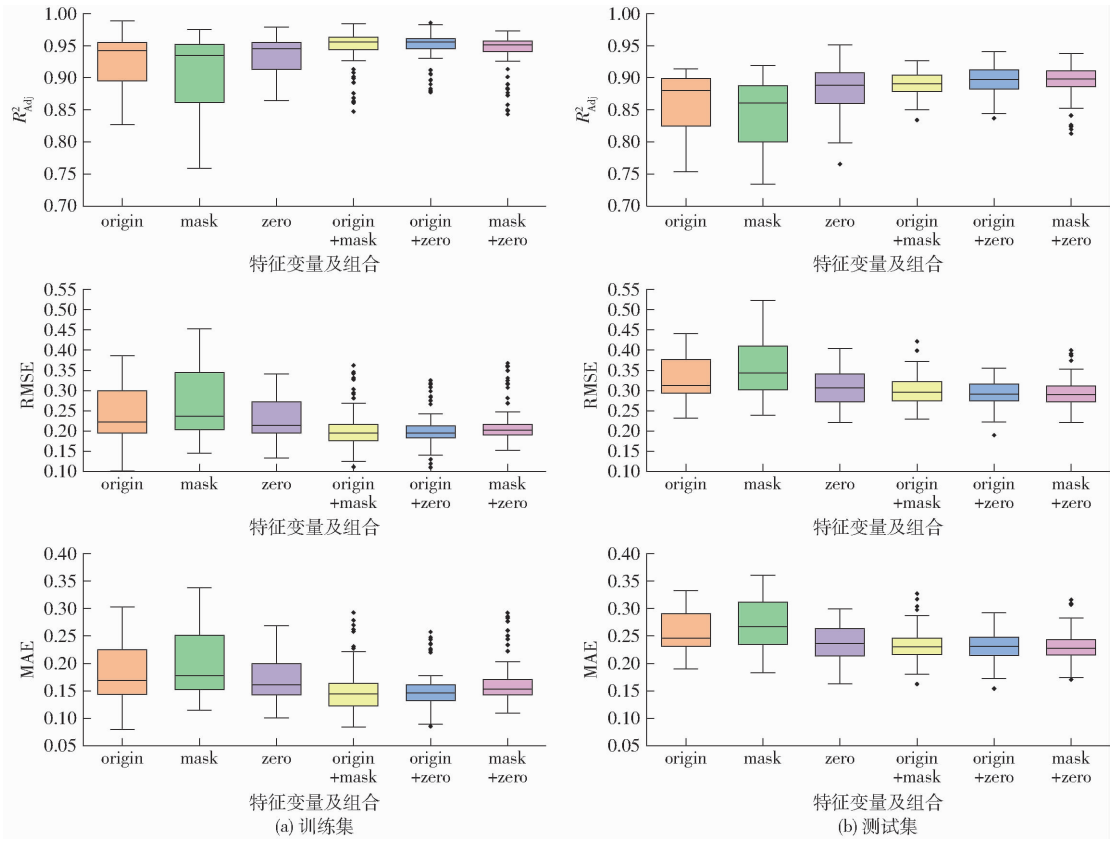

图 4　不同土壤背景去除方法下模型效果箱型图

Fig. 4　Box plots of modeling effects for different soil background removal methods

0.299 1)；由原始图像得到的模型效果次之(训练集 RMSE 为 0.102 0 ~ 0.386 9，MAE 为 0.079 9 ~ 0.302 9；测试集 RMSE 为 0.233 3 ~ 0.440 4，MAE 为 0.190 3 ~ 0.332 8)，由传统掩膜法得到的模型效果最差(训练集 RMSE 为 0.146 3 ~ 0.452 9，MAE 为 0.114 6 ~ 0.337 7；测试集 RMSE 为 0.240 2 ~ 0.523 9，MAE 为 0.182 7 ~ 0.359 6)。分别由不同土壤背景去除方式下的图像得到的植被指数/纹理特征的组合(origin + mask 表示来自原始图像的植被指数 + 来自传统掩膜法处理后图像的纹理特征或来自原始图像的纹理特征 + 来自传统掩膜法处理后图像的植被指数；origin + zero 表示来自原始图像的植被指数 + 来自本文所提方法处理后图像的纹理特征或来自原始图像的纹理特征 + 来自本文所提方法处理后图像的植被指数；mask + zero 表示来自传统掩膜法处理后图像的植被指数 + 来自本文所提方法处理后图像的纹理特征或来自本文所提方法处理后图像的植被指数 + 来自本文所提方法处理后图像的纹理特征)中，三者的 3 种评价指标箱型图之间体积相差较小，说明经过特征融合的模型效果更加稳定；三者的 R^2_{Adj} 最大值分别为训练集 0.985 0、0.985 8、0.973 1，测试集 0.927 0、0.940 8、0.937 8，结果表明，origin + zero 作为变量输入的模型效果更好。综合来看，模型效果最好的是以经过本文所提方法处理的图像提取的植被指数和纹理特征作为输入所得到的模型，其最优模型训练集/测试集 R^2_{Adj}、RMSE 和 MAE 分别为 0.975 5/0.951 5、0.141 5/0.242 1 和 0.112 4/0.179 5。

综上所述，不同的土壤背景去除方法中，传统掩膜法会降低光谱数据与 LAI 之间的相关性，导致模型效果较差，本文所提方法提高了光谱数据与 LAI 之间的相关性，其模型效果相较于未对土壤背景进行去除的原始光谱影像和经过传统掩膜法处理的光谱影像更好。因此，在建立光谱数据与 LAI 的估算模型之前，采用本文所提方法对遥感影像进行预处理更加合适。

2.1.2　不同输入特征类型对 LAI 估算模型精度的影响

对由不同输入特征类型下得到的多个模型效果进行统计并绘制对应的箱型图，如图 5 所示。其中，基于植被指数(VI)输入/基于纹理特征(Texture)输入的模型 R^2_{Adj}、RMSE 和 MAE 均值分别为：训练集 0.878 8/0.937 0、0.319 4/0.226 4、0.236 1/0.171 8，测试集 0.806 0/0.871 7、0.389 3/0.319 1、0.293 4/0.247 3，纹理特征对 LAI 的估算效果优于植被指数。植被指数与纹理特征融合作为模型输入(VI + Texture)的模型效果有所提升，其最优模型 R^2_{Adj} 相较于基于 VI/基于 Texture 的最优模型训练集和测试集分别提高 4.49%/1.69% 和 5.34%/2.57%，

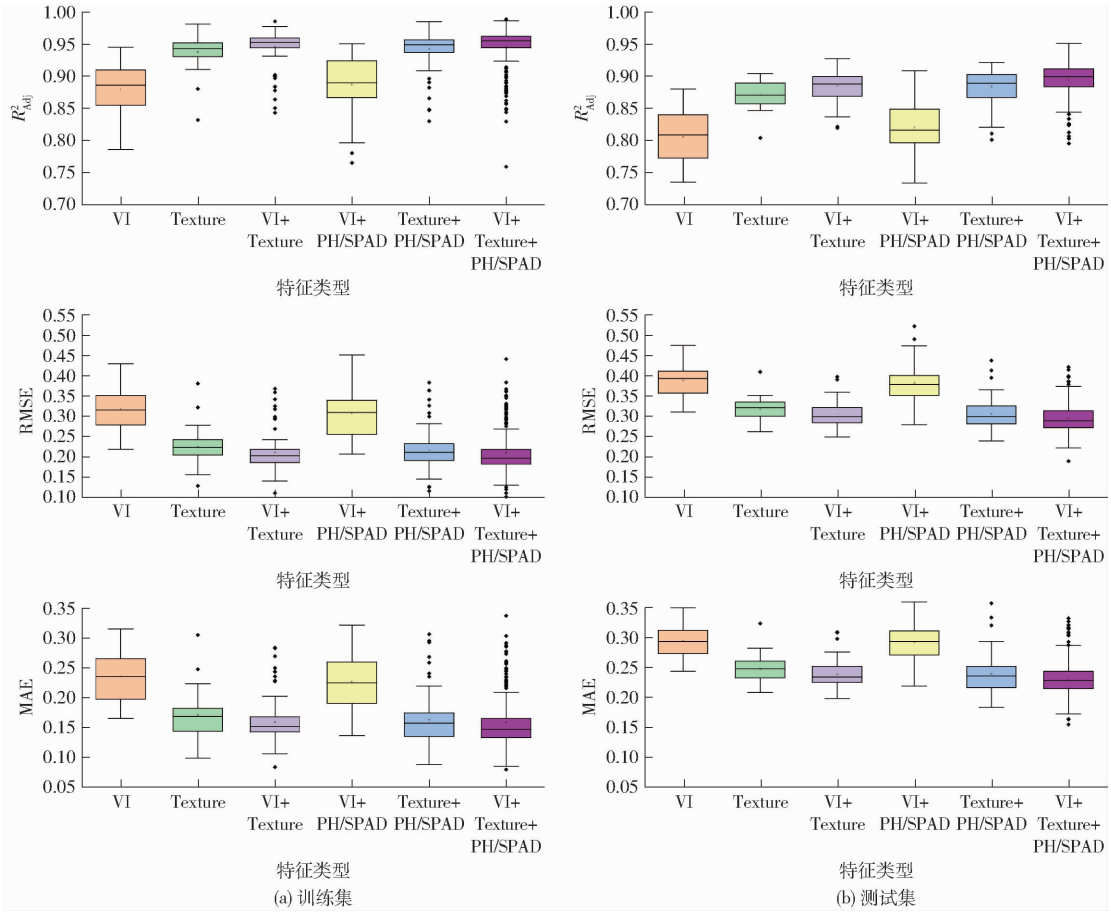

图 5 不同特征输入类型下模型效果的箱型图

Fig. 5 Box plots of modeled results for different feature input types

RMSE 分别降低 27.51%/25.70% 和 23.02%/4.80%。加入作物长势协变量后,基于 VI 输入(VI + PH/SPAD)/基于 Texture 输入(Texture + PH/SPAD)的模型效果相较于仅基于 VI/基于 Texture 输入的模型也有一定提升,但提升幅度较小,其最优模型的 R^2_{Adj} 分别提升 2.79%/0.40%(训练集)、3.20%/1.94%(测试集);RMSE 分别降低 18.55%/7.03%(训练集)、11.28%/1.33%(测试集);MAE 分别降低了 10.21%/7.35%(训练集)、10.20%/1.69%(测试集)。同时融合 VI、Texture 和作物长势协变量的模型效果最好,最优模型为 1D - CNN 模型,其训练集/测试集 R^2_{Adj}、RMSE 和 MAE 分别为 0.975 5/0.951 5、0.141 5/0.242 1 和 0.112 4/0.179 5。

综上所述,随着特征类型的增加,信息维度也随之增加,用于描述 LAI 的信息也更加全面,模型对 LAI 的估算精度也更高。因此,在建立 LAI 估算模型时,应优先选取多种类型的特征进行融合,以达到最优模型精度。

2.1.3 不同算法的建模效果分析

不同算法训练得到的最优模型效果如图 6 所示。随着特征类型和数据维度的增加,各算法模型效果均有不同程度的提升,提升最明显的是 MLR 模型,其训练集/测试集的 R^2_{Adj} 提升 12.41%/17.15%,RMSE 和 MAE 分别降低 49.29%/33.43% 和 48.48%/32.34%。SVR 模型提升程度最小,其训练集/测试集的 R^2_{Adj} 提升 4.48%/6.82%,RMSE 和 MAE 分别降低 27.34%/28.35% 和 27.03%/33.17%。传统统计回归算法(MLR、PLSR)的模型效果相比于机器学习算法较差,说明其对于特征的提取能力相对较差。几种由机器学习算法开发的模型中,ELM 模型稳定性最差,在 6 种不同类型特征输入中的效果排名差异最大,分别为第 7、5、8、4、5、3 名,SVR 模型和 1D - CNN 模型稳定性相对较好,排名分别为第 1、2、2、3、2、2 名和第 2、1、1、1、3、1 名,说明 SVR 和 1D - CNN 模型对输入的特征提取能力较强,且受特征类型变化的影响较小。ANN 模型随着输入特征类型的增加,模型效果虽有所增加,但相比于其他模型效果较差,排名逐渐降低,分别为第 4、3、5、5、6、6 名。说明随着输入特征类型的增加,ANN 模型的特征提取能力逐渐下降。

由单一土壤背景去除方法得到的多个 LAI 估算模型中,不同特征类型下的最优模型及其效果如表 2 所示。各种输入特征类型下的最优模型尽管有所不同,但均为机器学习模型,表明机器学习模型对

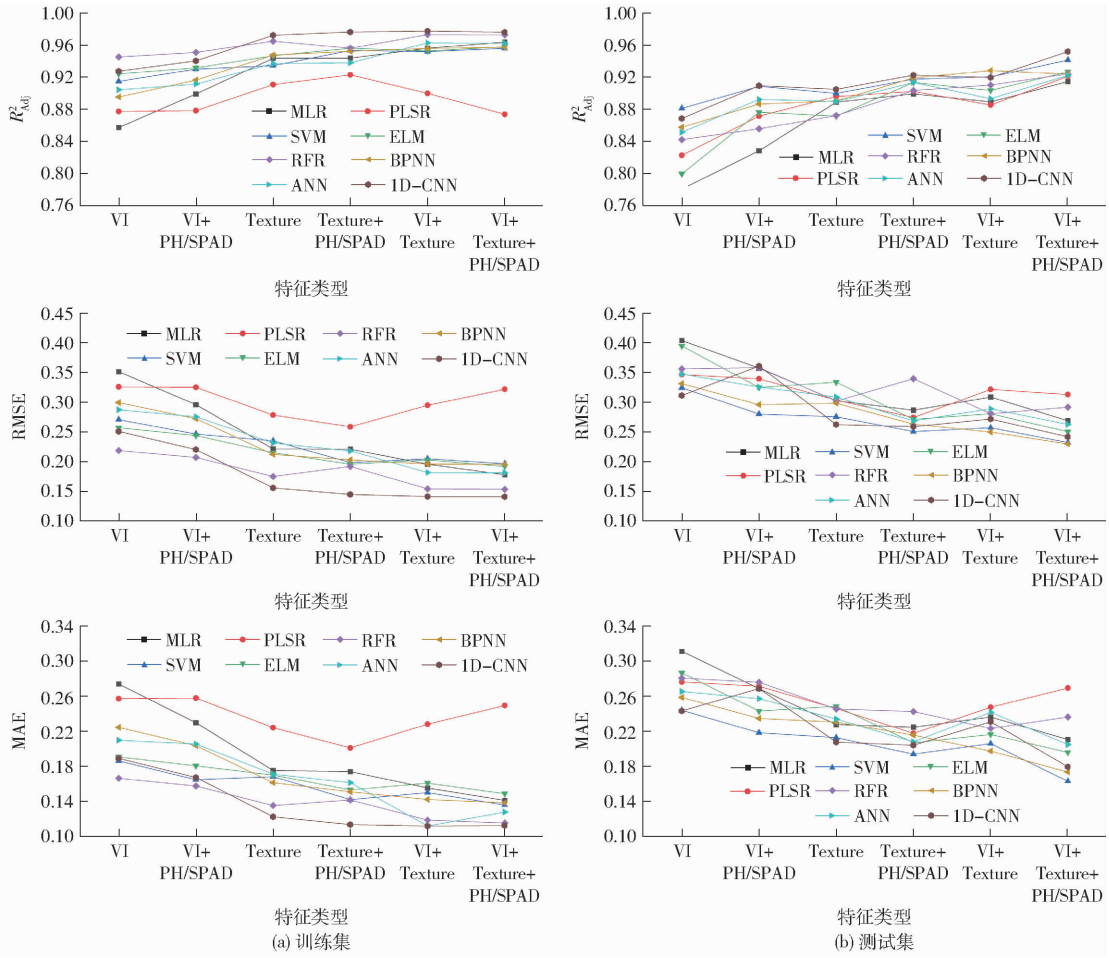

图 6　不同算法模型估算效果

Fig. 6　Model inversion results of different algorithms

表 2　不同类型输入特征下的最优模型及其结果

Tab. 2　Optimal models and their results under different types of input characteristics

土壤背景去除方法	输入特征类型	模型	训练集			测试集		
			R^2_{Adj}	RMSE	MAE	R^2_{Adj}	RMSE	MAE
不去除	VI	1D－CNN	0.895 3	0.300 9	0.228 8	0.841 3	0.363 5	0.287 7
	VI + PH/SPAD	1D－CNN	0.924 3	0.255 9	0.187 4	0.852 0	0.347 7	0.259 9
	Texture	SVR	0.950 6	0.206 2	0.151 0	0.897 5	0.282 3	0.216 2
	Texture + PH/SPAD	BPNN	0.956 0	0.194 8	0.136 3	0.907 2	0.300 6	0.247 0
	VI + Texture	1D－CNN	0.965 4	0.173 4	0.134 2	0.896 3	0.308 1	0.251 3
	VI + Texture + PH/SPAD	SVR	0.958 2	0.186 4	0.134 9	0.913 6	0.332 4	0.241 4
传统掩膜法	VI	BPNN	0.842 3	0.367 8	0.262 1	0.810 7	0.400 2	0.302 0
	VI + PH/SPAD	BPNN	0.850 3	0.360 8	0.271 0	0.821 3	0.372 3	0.296 1
	Texture	1D－CNN	0.971 3	0.157 5	0.125 4	0.895 7	0.282 3	0.214 2
	Texture + PH/SPAD	SVR	0.948 0	0.211 8	0.157 3	0.906 8	0.262 3	0.211 3
	VI + Texture	1D－CNN	0.974 0	0.149 6	0.117 6	0.915 6	0.283 5	0.205 1
	VI + Texture + PH/SPAD	SVR	0.951 6	0.204 3	0.147 9	0.919 7	0.258 1	0.201 3
本文方法	VI	SVR	0.914 3	0.271 2	0.186 1	0.880 8	0.324 5	0.244 0
	VI + PH/SPAD	1D－CNN	0.939 8	0.220 9	0.167 1	0.909 0	0.361 1	0.268 9
	Texture	1D－CNN	0.971 7	0.156 4	0.122 4	0.904 6	0.262 4	0.207 7
	Texture + PH/SPAD	1D－CNN	0.975 6	0.145 4	0.113 4	0.922 1	0.258 9	0.204 2
	VI + Texture	BPNN	0.955 3	0.196 6	0.142 1	0.927 9	0.280 1	0.197 4
	VI + Texture + PH/SPAD	1D－CNN	0.975 5	0.141 5	0.112 4	0.951 5	0.242 1	0.179 5

数据的特征提取能力更强。几种最优模型中，出现频次最高的是 1D－CNN 模型，充分说明了 CNN 深度学习算法的优异性能。综合来看，最优模型是以本文所提方法对土壤背景进行去除后，以 VI + Texture + PH/SPAD 作为输入特征的 1D－CNN 模型，其训练集/测试集 R^2_{Adj}、RMSE 和 MAE 分别为

0.975 5/0.951 5、0.141 5/0.242 1 和 0.112 4/0.179 5。

2.2 讨论

LAI 作为一种结构特征，在进行遥感估算时，土壤像素和植被像素的几何信息与其相关。直接对原始图像进行特征提取虽然保留了土壤像素与植被像素的几何信息，但土壤像素的反射率也会被引入感兴趣区域（Region of interest，ROI）平均光谱反射率的计算结果中，对后续植被指数等特征提取结果造成干扰，进而影响 LAI 估算模型的精度；传统的掩膜法直接将土壤像素去除，虽然消除了土壤反射率干扰，但也丢失了土壤与植被的几何信息，进而导致光谱反射率的“饱和”问题，而“饱和”问题会大大降低光谱反射率与 LAI 的相关性，最终导致 LAI 估算模型精度较差，这与文献[12]的研究结论一致；本文所提方法将土壤像素值置为“0”后，不仅保留了土壤像素与植被像素的面积信息，同时也消除了土壤光谱反射率对植被光谱的影响，因此能较好地对 LAI 进行表征，且其最优模型（以 VI + Texture + PH/SPAD 作为输入特征的 1D - CNN 模型）相较于文献[12]开发的基于 RSARE 指数的 LAI 估算模型和文献[14]开发的 GBDT 模型均取得了更好的效果，证明了本文所提出的土壤背景去除方法的有效性。图 7 展示了随着 LAI 的增加，不同波段光谱反射率的变化情况。NIR 波段和 Red Edge 波段的反射率明显区别于可见光波段，这表明 NIR 和 Red Edge 波段能更好地反映植被参数。此外，origin 图像和 mask 图像光谱反射率随 LAI 变化的规律并不明显，而 zero 图像光谱反射率与 LAI 之间呈现出较为明显的正相关趋势，表明本文所提方法能有效提高光谱反射率与 LAI 之间的相关性。

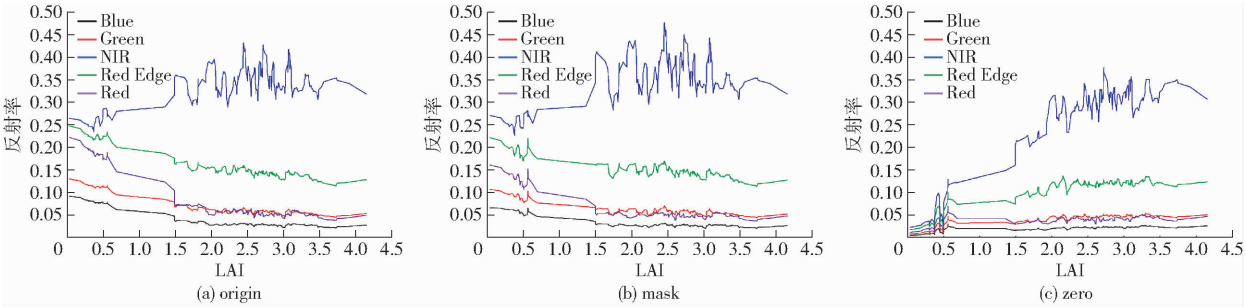

图 7 不同土壤背景去除方法下的光谱反射率

Fig. 7 Spectral reflectance under different soil background removal methods

在特征融合方面，除了考虑较为常用的植被指数和纹理特征进行融合外，还考虑了将作物长势协变量加入输入特征集合中，结果表明作物长势协变量的加入可在一定程度上提升 LAI 估算精度。与常见的多类型特征建模分析[15-18]不同，并非以植被指数作为 LAI 建模输入的主体，而是将植被指数和纹理特征均作为 LAI 建模输入的主体。结果表明，相较于植被指数，基于纹理特征的模型对于 LAI 的估算表现出了更好效果，因此，在后续 LAI 建模反演工作中可考虑将纹理特征作为 LAI 估算的主要输入特征。

不同土壤背景去除方法下植被指数和纹理特征与 LAI 的决定系数 R^2 变化情况如图 8 所示。在图 8a 中，基于 mask 图像提取的植被指数与 LAI 的 R^2 均低于 origin 和 zero 图像，基于 zero 图像提取的

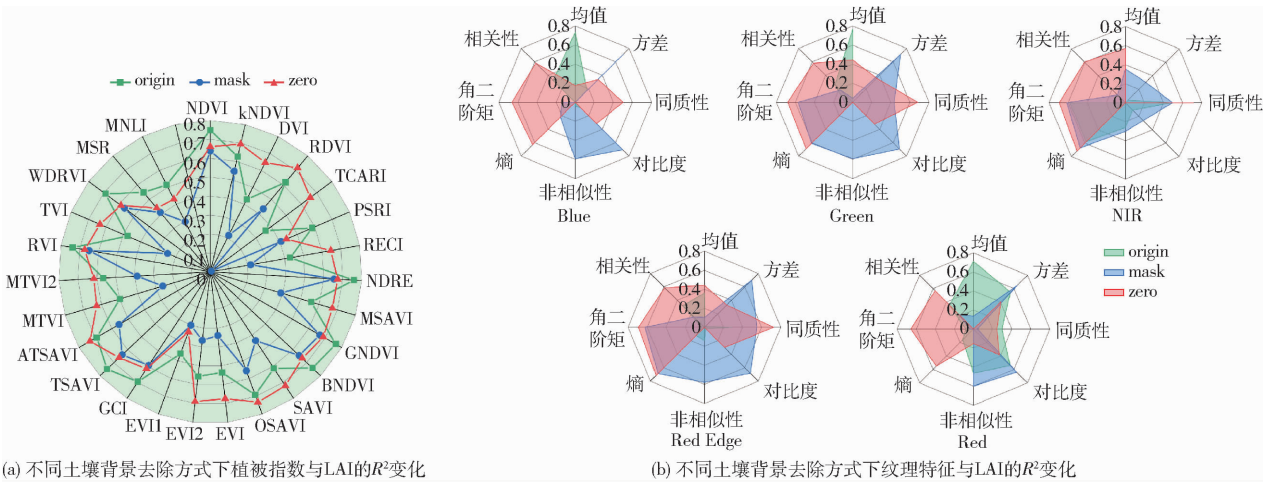

(a) 不同土壤背景去除方式下植被指数与LAI的R^2变化　(b) 不同土壤背景去除方式下纹理特征与LAI的R^2变化

图 8 不同土壤背景去除方法下特征与 LAI 的 R^2 变化

Fig. 8 Changes in R^2 between characterization and LAI under different soil background removal methods

植被指数中大部分表现出了与 LAI 良好的线性关系。在图 8b 中，zero 图像在 5 个波段中对熵、角二阶矩和相关性特征均表现出了稳定的提升效果；基于 origin 图像提取的可见光波段的均值特征与 LAI 的相关性较强；基于 mask 图像提取的可见光波段和红边波段的方差、对比度、非相似性特征与 LAI 的 R^2 较高。综上所述，为进一步降低模型输入特征的维度和模型复杂度，在后续 LAI 估算建模工作中可根据不同土壤背景去除方式对植被指数和纹理特征的提升效果，有针对性地提取对应的特征作为模型输入，训练更加轻量化和更加稳健的模型。

3　结论

（1）相对于不去除土壤背景，传统掩膜法由于忽略了土壤和植被的面积信息导致所提特征与 LAI 的相关性变差，本文所提方法可有效提高遥感影像与 LAI 的相关性。

（2）输入特征类型增加会提高模型预测精度，纹理特征对于 LAI 的反演效果优于植被指数，作物长势协变量的加入有助于增加 LAI 模型反演精度，LAI 估算最优输入特征集合为 VI + Texture + PH/SPAD。

（3）不同输入特征集合下的最优模型不同，但均为机器学习模型，综合效果最好的是经本文所提土壤背景去除方法预处理后以 VI + Texture + PH/SPAD 作为输入的 1D - CNN 模型，其测试集 R^2_{Adj}、RMSE 和 MAE 分别为 0.951 5、0.242 1 和 0.179 5。综上所述，本文方法可快速、准确估算玉米 LAI。

参　考　文　献

[1] 张宏鸣，侯贵河，孙志同，等. 基于 XGBoost - Shapley 的玉米不同生育期 LAI 遥感估算[J]. 农业机械学报，2022，53(7)：208 - 216，225.
ZHANG Hongming，HOU Guihe，SUN Zhitong，et al. Remote sensing estimation of maize leaf area index at different growth periods based on XGBoost - Shapley algorithm[J]. Transactions of the Chinese Society for Agricultural Machinery，2022，53(7)：208 - 216，225.（in Chinese）

[2] BATES J S，MONTZKA C，SCHMIDT M，et al. fUAS LiDAR crop LAI estimations from canopy density[C]// 2021 IEEE International Geoscience and Remote Sensing Symposium IGARSS，2021：7720 - 7723.

[3] SUN X，ZHANG Y，SHI K，et al. Monitoring water quality using proximal remote sensing technology[J]. Science of the Total Environment，2022，803：149805.

[4] MORALES-SANTOS A，GARCÍA-VILA M，NOLZ R. Assessment of the impact of irrigation management on soybean yield and water productivity in a subhumid environment[J]. Agricultural Water Management，2023，284：108356.

[5] OLSON D，ANDERSON J. Review on unmanned aerial vehicles，remote sensors，imagery processing，and their applications in agriculture[J]. Agronomy Journal，2021，113(2)：971 - 992.

[6] 许童羽，白驹驰，郭忠辉，等. 基于无人机高光谱遥感的水稻氮营养诊断方法[J]. 农业机械学报，2023，54(2)：189 - 197，222.
XU Tongyu，BAI Juchi，GUO Zhonghui，et al. Diagnosis method of rice nitrogen deficiency based on UAV hyperspectral remote sensing[J]. Transactions of the Chinese Society for Agricultural Machinery，2023，54(2)：189 - 197，222.（in Chinese）

[7] NIU Y，HAN W，ZHANG H，et al. Estimating fractional vegetation cover of maize under water stress from UAV multispectral imagery using machine learning algorithms[J]. Computers and Electronics in Agriculture，2021，189：106414.

[8] PENG X，HAN W，AO J，et al. Assimilation of LAI derived from UAV multispectral data into the SAFY model to estimate maize yield[J]. Remote Sensing，2021，13(6)：1094.

[9] GAO L，DARVISHZADEH R，SOMERS B，et al. Hyperspectral response of agronomic variables to background optical variability：results of a numerical experiment[J]. Agricultural and Forest Meteorology，2022，326：109178.

[10] LIU S，JIN X，NIE C，et al. Estimating leaf area index using unmanned aerial vehicle data：shallow *vs* deep machine learning algorithms[J]. Plant Physiology，2021，187(3)：1551 - 1576.

[11] ZHANG L，HAN W，NIU Y，et al. Evaluating the sensitivity of water stressed maize chlorophyll and structure based on UAV derived vegetation indices[J]. Computers and Electronics in Agriculture，2021，185：106174.

[12] LI W，LI D，LIU S，et al. RSARE：a physically-based vegetation index for estimating wheat green LAI to mitigate the impact of leaf chlorophyll content and residue-soil background[J]. ISPRS Journal of Photogrammetry and Remote Sensing，2023，200：138 - 152.

[13] LIU S，JIN X，BAI Y，et al. UAV multispectral images for accurate estimation of the maize LAI considering the effect of soil background[J]. International Journal of Applied Earth Observation and Geoinformation，2023，121：103383.

[14] LIANG L，GENG D，YAN J，et al. Estimating crop LAI using spectral feature extraction and the hybrid inversion method[J]. Remote Sensing，2020，12(21)：3534.

[15] YANG K，GONG Y，FANG S，et al. Combining spectral and texture features of UAV images for the remote estimation of rice LAI throughout the entire growing season[J]. Remote Sensing，2021，13(15)：3001.

[16] QIAO L，GAO D，ZHAO R，et al. Improving estimation of LAI dynamic by fusion of morphological and vegetation indices based on UAV imagery[J]. Computers and Electronics in Agriculture，2022，192：106603.

[17] LI H，YAN X，SU P，et al. Estimation of winter wheat LAI based on color indices and texture features of RGB images taken by UAV[J]. Journal of the Science of Food and Agriculture，2025，109(1)：189 - 200.

[18] 范军亮, 王涵, 廖振棋, 等. 基于纹理-颜色特征与植被指数融合的冬小麦 LAI 估测[J]. 农业机械学报, 2023, 54(7): 347 - 359.
FAN Junliang, WANG Han, LIAO Zhenqi, et al. Winter wheat leaf area index estimation based on texture - color features and vegetation indices[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(7): 347 - 359. (in Chinese)
[19] SHAO G, HAN W, ZHANG H, et al. Mapping maize crop coefficient *Kc* using random forest algorithm based on leaf area index and UAV-based multispectral vegetation indices[J]. Agricultural Water Management, 2021, 252: 106906.
[20] MYNENI R B, WILLIAMS D L. On the relationship between FAPAR and NDVI[J]. Remote Sensing of Environment, 1994, 49(3): 200 - 211.
[21] GAO S, ZHONG R, YAN K, et al. Evaluating the saturation effect of vegetation indices in forests using 3D radiative transfer simulations and satellite observations[J]. Remote Sensing of Environment, 2023, 295: 113665.
[22] VERRELST J, SCHAEPMAN M E, KOETZ B, et al. Angular sensitivity analysis of vegetation indices derived from CHRIS/PROBA data[J]. Remote Sensing of Environment, 2008, 112(5): 2341 - 2353.
[23] GONENC A, OZERDEM M S, ACAR E. Comparison of NDVI and RVI vegetation indices using satellite images[C]// 2019 8th International Conference on Agro-Geoinformatics (Agro-Geoinformatics), 2019: 1 - 4.
[24] REN S, CHEN X, AN S. Assessing plant senescence reflectance index-retrieved vegetation phenology and its spatiotemporal response to climate change in the Inner Mongolian Grassland[J]. International Journal of Biometeorology, 2017, 61(4): 601 - 612.
[25] KARNATI R, PRASAD M V S. A prediction of crop monitoring indices (NDVI, MSAVI, RECI) and estimation of nitrogen concentration on leaves for possible of optimizing the time of harvest with the help of sensor networks in Guntur Region, Andhra Pradesh, India with agent based modeling[J]. International Journal of Advanced Science and Computer Applications, 2023, 2(1): 19 - 30.
[26] HABOUDANE D, MILLER J R, PATTEY E, et al. Hyperspectral vegetation indices and novel algorithms for predicting green LAI of crop canopies: modeling and validation in the context of precision agriculture[J]. Remote Sensing of Environment, 2004, 90(3): 337 - 352.
[27] CHOI B, LEE J, PARK B, et al. A study of cyanobacterial bloom monitoring using unmanned aerial vehicles, spectral indices, and image processing techniques[J]. Heliyon, 2023, 9(5): e16343.
[28] LIU M, ZHAN Y, LI J, et al. Validation of Red-Edge vegetation indices in vegetation classification in tropical monsoon region—a case study in Wenchang, Hainan, China[J]. Remote Sensing, 2024, 16(11): 1865.
[29] KURBANOV R K, ZAKHAROVA N I. Application of vegetation indexes to assess the condition of crops[J]. Agricultural Machinery and Technologies, 2020, 14(4): 4 - 11.
[30] JORGE J, VALLBÉ M, SOLER J A. Detection of irrigation inhomogeneities in an olive grove using the NDRE vegetation index obtained from UAV images[J]. European Journal of Remote Sensing, 2019, 52(1): 169 - 177.
[31] WANG Q, MORENO-MARTÍNEZ Á, MUÑOZ-MARÍ J, et al. Estimation of vegetation traits with kernel NDVI[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2023, 195: 408 - 417.