doi:10.6041/j.issn.1000-1298.2024.S2.028

基于CNN-LSTM的苹果树种植区域提取

王子航[1,2] 常 晗[1,2] 张 瑶[1,2] 郭树欣[1,2] 张海洋[1,2]

（1. 中国农业大学信息与电气工程学院，北京 100083；
2. 中国农业大学智慧农业系统集成研究教育部重点实验室，北京 100083）

摘要： 苹果树种植区域提取有利于农业资源高效管理。为解决苹果种植区域提取中存在的分类精度不高、时效性滞后等问题，提出一种基于Sentinel-2和MODIS融合影像的卷积神经网络-长短期记忆网络（CNN-LSTM）时序分类模型。首先采用ESTARFM时空融合算法构建融合影像，对不同卫星影像在空间和时间监测能力优势和缺陷进行互补，得到高空间和高时间分辨率共存的影像数据。在特征选择方面，通过随机森林模型进行重要性分析并结合后向特征消除法从25个原始特征中选15个关键特征变量作为最优特征组合。分类模型方面，卷积神经网络（Convolutional neural network, CNN）可以很好地在空间域、光谱域提取有效特征。长短期记忆网络（Long short-term memory, LSTM）作为循环神经网络（Recurrent neural network, RNN）的改进，可以处理不等长的输入序列。二者结合能够提取“时空谱”有效特征，实现更精准的图像分类和遥感数据分析。以烟台市牟平区观水镇为研究区，利用时空融合弥补原始Sentinel-2的影像缺失，使用CNN-LSTM模型进行苹果树种植区域提取，并与常用的机器学习分类算法进行对比，进而确定最优分类模型。研究表明在苹果种植区域提取方面CNN-LSTM模型总体精度为97.98%，Kappa系数为0.958 6，总体精度对比其他4种机器学习算法CART、SVM、RF、GBDT分别高15.43、5.25、4.00、3.31个百分点，与LSTM模型总体精度和Kappa系数相比分别提高2.11个百分点和0.0148。所提出的苹果树种植区域精准遥感提取方法可为制定科学合理的农业管理措施提供有力支持。

关键词： 深度学习；卷积神经网络；CNN-LSTM；苹果树种植区域提取

中图分类号： TP75 **文献标识码：** A **文章编号：** 1000-1298(2024)S2-0277-09

Apple Planting Area Extraction Based on Improved CNN-LSTM Model

WANG Zihang[1,2] CHANG Han[1,2] ZHANG Yao[1,2] GUO Shuxin[1,2] ZHANG Haiyang[1,2]

（1. *College of Information and Electrical Engineering, China Agricultural University, Beijing* 100083, *China*
2. *Key Laboratory for Modern Precision Agriculture System Integration Research, Ministry of Education, China Agricultural University, Beijing* 100083, *China*）

Abstract: The efficient management of agricultural resources can be significantly improved through the accurate extraction of apple cultivation areas. In order to solve the problems of poor classification accuracy and time lag in apple planting area extraction, a CNN-LSTM temporal classification model was proposed based on Sentinel-2 and MODIS fusion images. The ESTARFM spatio-temporal fusion algorithm was firstly used to construct the fusion image, which complemented the strengths and weaknesses of different satellite images in spatial and temporal monitoring capabilities, and obtained image data with high spatial and temporal resolution. The random forest model was utilized to select the most optimal feature combinations from the initial 25 features, narrowed down to 15 key variables using backward feature elimination. In terms of classification models, convolutional neural networks (CNN) can well extract effective features in the spatial and spectral domains. As an improvement of recurrent neural network, long short-term memory network (LSTM) can handle unequal input sequences. The combination of the two networks proposed can extract effective features in the spatial, temporal and spectral domains to achieve more accurate image classification and remote sensing data analysis. Taking Guanshui Town, Muping District, Yantai City as the study area, the spatio-temporal fusion algorithm was utilized to compensate for the lack of images from a single Sentinel-2, and the CNN-LSTM model was used for apple tree planting area extraction. The CNN-LSTM model achieved an overall accuracy of

收稿日期：2024-07-16 修回日期：2024-09-23

基金项目： 国家自然科学基金面上项目(32471993)

作者简介： 王子航(2001—)，男，硕士生，主要从事深度学习在农业智能检测方面的应用研究，E-mail: wangzihang@cau.edu.cn

通信作者： 张瑶(1988—)，女，副教授，主要从事农业定量遥感应用研究，E-mail: zhangyao@cau.edu.cn

97.98% and a Kappa coefficient of 0.958 6, outperforming the other four machine learning algorithms by 15.43 percentage points, 5.25 percentage points, 4.00 percentage points, and 3.31 percentage points, respectively. The overall accuracy and Kappa coefficient of the CNN-LSTM model were improved by 2.11 percentage points and 0.0148, respectively, compared with that of the LSTM model. The precise remote sensing extraction method for apple tree planting areas proposed can provide strong support for the development of scientific and rational agricultural management.

Key words: deep learning; convolutional neural network; CNN-LSTM; apple planting area extraction

0 引言

苹果是全球四大水果之一,有丰富的营养价值和诸多保健作用,故有“活水”之称[1]。在我国,苹果的总产量近二十年来都位于所有水果产量之首[2],同时我国也是世界上苹果生产、消费和出口量最大的国家[3]。烟台是中国苹果的发祥地,拥有超过150年苹果栽培生产发展历史[4]。对烟台苹果树种植区域的精准提取,有利于提高作物管理和生产的精确度,最大化作物产量并提升品质。农作物种植区域的准确把握,对于监测农作物的生长状况、产量预估以及灾害评估等多方面具有重大意义。

目前基于卫星遥感技术进行农作物种植区域提取的相关技术按种类大致可分为3种:以物候信息为基础的自动提取技术[5],以传统机器学习为基础的区域提取技术[6]和以深度学习为基础的农作物种植区域提取技术[7]。

基于时序物候信息的作物分类算法利用作物生长周期中的关键阶段物候信息和遥感数据的特定特征如反射率、植被指数来设置阈值[8]。通过这些阈值,算法能够区分不同类型作物或识别作物生长状态。利用时间序列的NDVI、EVI数据可以捕捉到作物生长的关键时期,还可以帮助手动设定基于阈值的分类规则[9]。HUANG等[10]研究了合成时间序列NDVI中提取的时间特征对土地分类的影响。然而,当环境或作物条件发生变化时,这些阈值可能不再适用,这种方法缺乏灵活性,不能很好地适应不同地区或不同年份的变化。

随着输入数据维度的增加,机器学习模型能够更深入地挖掘这些复杂数据中的潜在信息,从而提高分类的准确性。近年来,决策树、随机森林、支持向量机等机器学习算法在这个领域中显示了巨大的潜力[11-12]。然而在处理大规模多时相遥感数据集时,传统机器学习算法难以充分捕捉农作物和环境之间大量复杂的非线性关系。

相比于传统机器学习,深度学习减少了对传统手工进行的特征工程的依赖,进而向自我学习和自我适应转变[13]。卷积神经网络(Convolutional neural network, CNN)可以提取遥感影像中的空间域和光谱域特征,从而在多层次上揭示数据中的重要信息。JAMALI等[14]基于Sentinel-1和Sentinel-2数据,使用复杂的多模型深度网络绘制了加拿大湿地遗址,准确率为92.3%。而长短期记忆网络(Long short-term memory, LSTM)可以通过处理时间序列数据中的时间依赖性,更好地处理具有时间维度的数据。LIN等[15]在Sentinel-1数据上使用了基于长短期记忆模块的设计,美国稻田制图的准确率为98.3%。CHEN等[16]在Sentinel-2数据上使用双向LSTM设计对中国地区的作物类型进行分类,总体准确率约为97%。CAMPOS-TABERNER等[17]提供了一个与RF分类器比较的例子,其中基于Sentinel-2数据的双向LSTM在作物类型分类总体准确率为98.7%。但是单独的空间光谱特征或者时序特征都不能完整地体现出作物生长过程的全部信息,如何将空间域和时间域的特征融合,进一步提高种植区域提取精度,值得进一步分析与研究。

基于此,本研究提出一种基于CNN和LSTM融合的新型网络结构,对Sentinel-2原始影像使用ESTARFM算法进行时空融合完善,构建苹果生长全过程的时间序列数据集,并充分利用研究区光谱波段、光谱指数、纹理和地形等多维特征,结合CNN与LSTM各自优势对“时空谱”有效特征进行提取,以期实现更准确的苹果树种植区域提取。

1 研究区及数据源

1.1 研究区概况

选取中国山东省烟台市牟平区观水镇为研究区(图1),观水镇地貌属于剥蚀丘陵类型,这种地貌的形成及其特点对当地的农业生产尤其是果树种植有着深远影响。同时观水镇的温带季风型大陆性气候为苹果等果树的生长提供了理想的温度和湿度环境。观水镇苹果的物候期分为萌芽期、花期、幼果期、果实膨大期和着色成熟期,从3月开始萌芽到10月成熟收获。

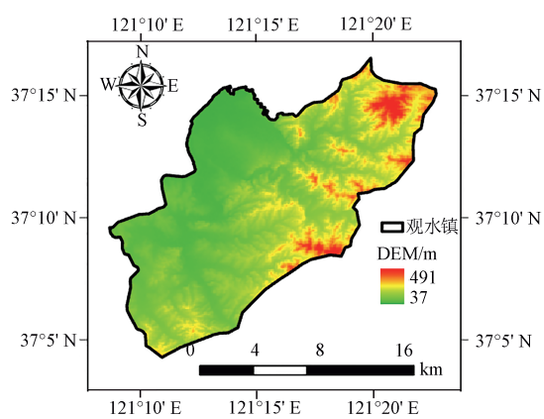

图1 研究区示意图

Fig. 1 Diagram of study area

1.2　遥感数据获取及预处理

1.2.1　Sentinel-2遥感数据

哨兵二号（Sentinel-2）卫星群是由欧洲航天局（ESA）开发的高级卫星观测系统，由两颗卫星组成：Sentinel-2A和Sentinel-2B，为研究地球表面植被、土壤、水体等特征提供了丰富信息[18-20]。本研究获取Sentinel-2 L2A地表反射率影像集2023年研究区域的影像，排除了云量超过10%的影像，并进行了3次卷积差值和重采样处理，确保所获得的Sentinel-2影像集在空间、光谱和时间分辨率上均满足研究需求。

1.2.2　MODIS遥感数据

中分辨率成像光谱仪（Moderate-resolution imaging spectroradiometer，MODIS）是装载在Terra和Aqua两颗卫星上的关键传感器，它们共同工作以实现近乎全天候的全球覆盖。MODIS可以为气候变化监测[21]、植被指数计算[22]、陆地水分监测[23]等研究提供理想完整的数据源。本研究基于GEE平台获取名为“MODIS/061/MOD09A1”的500 m地表反射率8d合成产品。为了确保数据的准确性和可靠性，MODIS数据经过了一系列大气校正处理，以消除或减少气溶胶、气体和瑞利散射等大气因素对观测数据的影响。

1.2.3　Google Earth Engine遥感大数据分析云平台

Google Earth Engine（GEE）是由Google推出的对大量全球尺度地球科学资料进行在线可视化分析计算处理的平台，提供了超过50 PB的庞大免费数据集资源，这些数据集覆盖了Landsat、哨兵卫星系列、MODIS系列产品，以及包括地形、气候和高程等多种类型的数据。GEE云计算平台不仅大幅提升了处理速度和运算能力，还显著降低了技术门槛，易于上手和学习，为农作物分类研究提供了一个高效、易用且功能强大的分析平台[24]。在这一平台支持下，本研究成功地应用了多种分类模型对试验区的地物进行了精确分类。

1.3　样本数据

本研究所采用的样本数据收集方法综合了野外实地调查和目视解译两种技术以满足分类和精度验证的需要。利用奥维地图进行GPS定位，特别关注苹果种植区的周边和关键区域，以确保采集到的GPS坐标点能够准确反映地物类型的多样性。这些坐标点不仅与实地调查记录相结合，还通过Google Earth软件的目视解译功能进行了扩充，以增加样本的覆盖范围和类型。综合野外实地调查与目视解译共获得884个有效样本点，包含苹果302个，水体134个，建筑物254个，其他地物类型194个。后续模型分类即分为苹果区域、水体区域、建筑物和其他区域4大类进行训练分类，并将所得样本数据按照比例8∶2随机划分为训练集和测试集。图2为部分实地考察记录。

1.4　数据增强

在处理像元的遥感影像时间序列数据时，由于土地覆盖类型的时间序列特性及其复杂性以及噪声的干扰，获取数量充足且质量高的训练样本显得尤为困难，为解决训练样本不足导致的过拟合现象，采用一系列数据增强方法，以扩大训练集的规模。这些方法能够有效增加用于训练的影像数据量，从而帮助深度网络模型更好地泛化。然而，数据增强带来了一个新问题：原始样本在扩增后训练集中的比例减少。为了解决这一问题，提出一种平衡策略，即通过复制未经扩增的样本集，保持合成数据与真实数据之间的平衡。

采用截断扩增、混合扩增和平移缩放[25]3种数据扩增方法。3种方法均将每一类别的地物区域数量扩增至原始数目的10倍，此外，为保持对原始数据的依赖和平衡，对原始训练数据执行了20倍的复制操作，最终每1幅影像的训练数据集样本数量为884×0.8×50=35 360个。

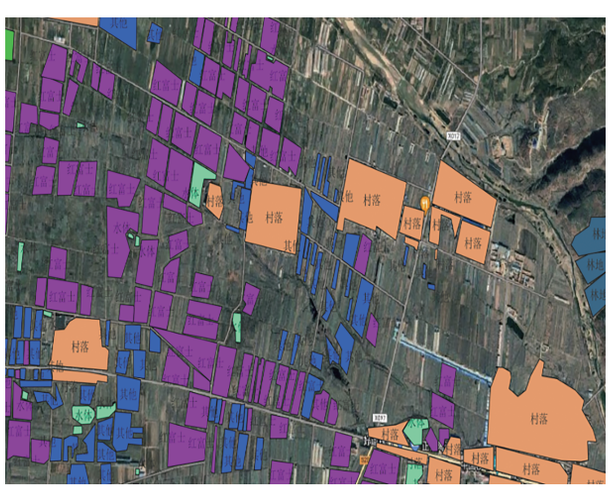
村落
村落
村落

2 研究方法

2.1 Sentinel-2与MODIS影像时空融合

使用ESTARFM[26]对MODIS高时间分辨率影像和Sentinel-2高空间分辨率影像数据进行时空融合，选取2023年4月26日的影像对（MODIS低空间高时间分辨率影像和Sentinel-2高空间低时间分辨率影像）和2023年6月15日的影像对用作算法输入；随后将2023年5月16日的MODIS影像作为融合目标，运用ESTARFM算法，成功生成具有高空间分辨率特征的5月16日融合影像。同样地，将2023年7月10日和2023年9月28日的影像对作为输入，并以8月31日的MODIS影像为目标，通过ESTARFM算法，得到2023年8月31日的高空间分辨率融合影像，对因云雨天气缺失的影像进行填补，构建时间序列数据集。2023年Sentinel-2遥感影像数据如表2所示，原始影像与融合影像如图3所示。

表2 2023年Sentinel-2遥感影像数据

Tab. 2 Sentinel-2 remote sensing imagery data 2023

序号	日期	获取方式	序号	日期	获取方式
1	2023-01-18	直接获取	7	2023-07-10	直接获取
2	2023-02-20	直接获取	8	2023-08-31	时空融合
3	2023-03-14	直接获取	9	2023-09-28	直接获取
4	2023-04-26	直接获取	10	2023-10-23	直接获取
5	2023-05-16	时空融合	11	2023-11-02	直接获取
6	2023-06-15	直接获取	12	2023-12-09	直接获取

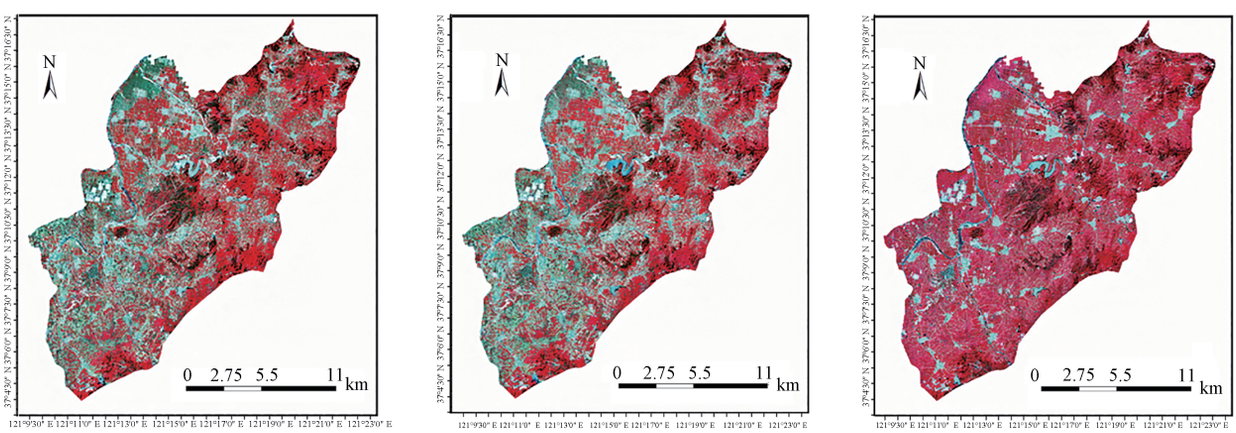

(a) 6月15日Sentinel-2原始影像 (b) 5月16日融合影像 (c) 8月31日融合影像

图3 原始影像与融合影像展示

Fig. 3 Original and fusion image presentation

2.2 基于随机森林基尼指数的最优特征集构建

本研究采用基于基尼指数的封装型随机森林算法评估特征重要性并进行特征优选，通过对特征的重要性进行计算和评分，保留得分高且对分类贡献最大的特征，得出最优特征集[27]。基尼系数是衡量样本纯净度的一个指标，反映了从样本集中准确地分离出各类别的难易程度。一般而言，基尼系数越小，表明样本同质性越高，即“纯净度”越高[28]。应用随机森林算法对遥感影像中提取的特征进行重要性分析，以评估各特征在分类任务中的贡献度。随机森林算法通过构建多棵决策树并在每次分裂中引入特征选择的随机性，有效地降低了模型的过拟合风险，从而增强了模型的泛化能力。

2.3 CNN-LSTM模型

CNN能够高效地对遥感图像进行分类，识别出具体的物体或特征[29]。LSTM是一种特殊类型的循环神经网络，核心在于其独特的记忆单元结构，该结构能够学习并记住长期的依赖信息，从而有效捕捉长期依赖关系[30]。

综合以上两种网络的优势，提出一种CNN-LSTM模型。CNN-LSTM模型包括两个特征提取分支：空谱特征提取分支和时序特征提取分支。在空间-光谱波段特征增强阶段，采用一种混合的3D与2D卷积神经网络架构，这种架构有效提升了空间和光谱波段特征的表达力。随后，为了捕捉和利用时间序列中的动态信息，本模型在基于2D卷积神经网络提取的空间-光谱波段特征基础上，进一步整合了LSTM网络，以获得结合时间、空间和光谱维度的深层特征。此方法的提出，旨在实现更为精细化的信息提取和更高效的特征整合，以期在相关的分类任务中取得显著的性能提升。图4为CNN-LSTM的模型结构。

空谱特征提取分支：该层使用三维卷积核提取高光谱图像的空间和光谱波段特征，随后通过池化层减少数据维度，提取最显著特征，减少计算量并避免过拟合。特征在光谱维度上聚合后，网络利用2D卷积层进一步提取空间特征，从而捕捉图像的局部特征和上下文信息，为分类任务提供有用的空间和光谱特征。

时序特征提取分支：该分支通过2D卷积层直接从图像的空间维度提取特征，专注于捕捉图像的纹理和形状信息。接着使用LSTM处理图像特征，捕捉图像序列间的时序关联性，这在处理时间序列数据或需要考虑前后文关系的场景中非常有用。LSTM处理后，通过池化层减少数据维度并汇总重要的时序特征。

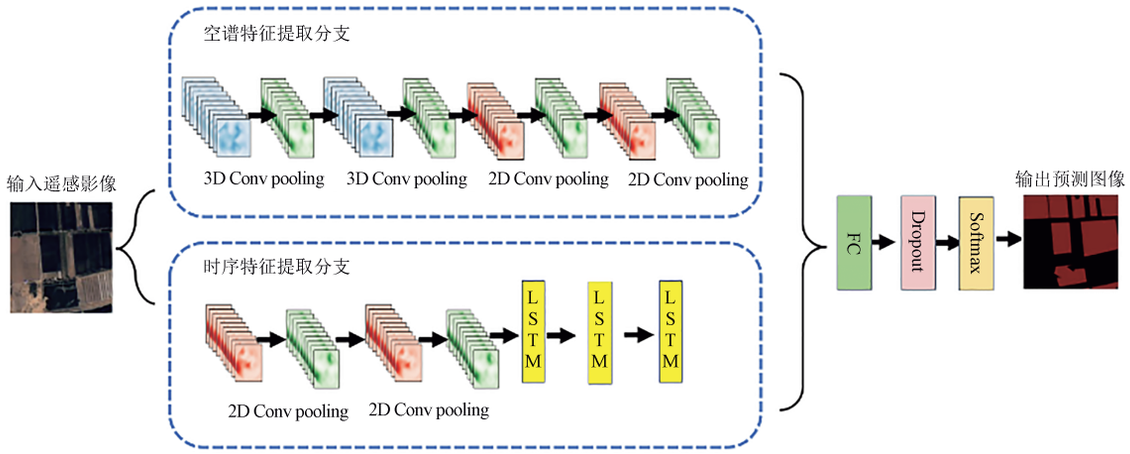

图4　CNN-LSTM模型结构图

Fig. 4　CNN-LSTM network structure diagram

这两个分支的输出随后合并，并通过全连接层和Dropout层进行处理，Dropout层用于减轻或防止过拟合。最终，Softmax层将神经网络的输出转化为概率分布，对应不同的分类标签。

在空谱增强分支中，主要包括2个三维卷积层和2个二维卷积层，每个卷积层后面都跟有一个最大池化，2个三维卷积层的卷积核分别为(93,3,7)和(3,3,5)，2个二维卷积层的卷积核均为(3,3)，三维卷积层之后的最大池化尺寸为(2,2,1)，二维卷积层之后的最大池化尺寸为(2,2)。时序增强分支中，包括2个二维卷积层，卷积核的大小均为(3,3)，二维卷积层之后的最大池化尺寸为(2,2)，之后经过包装层将所有特征处理后输入到LSTM模型，堆叠的LSTM层数设置为3，LSTM每层隐藏层单元数被设置为128。最后全连接层经过Dropout层后，输入Softmax层得到最终的分类结果，训练过程中Dropout的概率被设定为0.5来防止模型过拟合，使用带有Adam优化器的反向传播算法来训练网络，beta1=0.9，beta2=0.999，实验中的迭代训练次数设置为100，批次大小为128，学习率为0.001。

3　实验结果与分析

3.1　ESTARFM时空融合模型结果与精度评价

针对5月16日和8月31日合成的遥感影像以及6月15日的原始影像进行定量分析，计算其均方根误差(RMSE)、平均绝对误差(MAE)和决定系数(R^2)值。图5展示了融合反射率和实际反射率散点图。

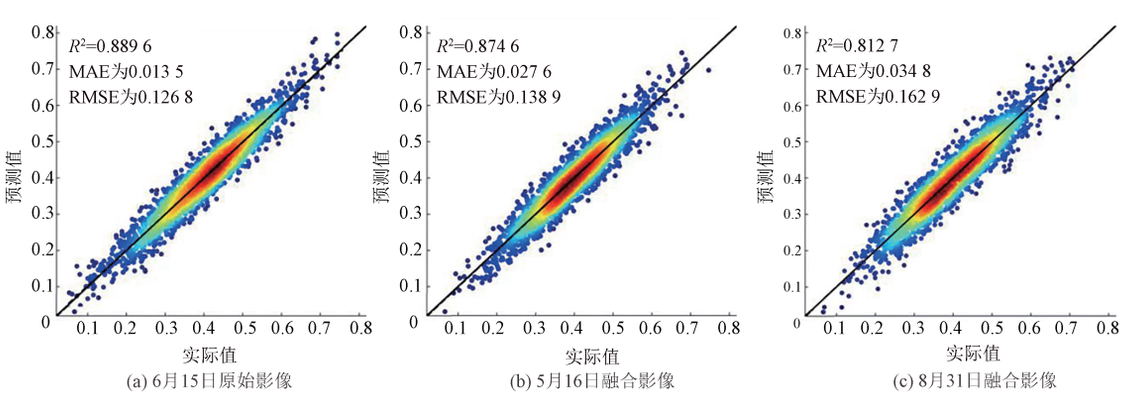

(a) 6月15日原始影像　(b) 5月16日融合影像　(c) 8月31日融合影像

图5　融合反射率与实际反射率散点图

Fig. 5　Scatter plots of fused reflectance and actual reflectance

从图5可以看出，融合后的5月16日和8月31日影像R^2均在0.8以上，这说明预测值与观测结果具有很高的相似性，平均绝对误差和均方根误差均非常小，都接近于0。说明融合影像均已达到可以作为数据集的标准，可以用时空融合影像来弥补因云雨天气造成的Sentinel-2影像缺失，从而构建长时间序列影像数据集。

3.2　最优特征集构建结果

使用随机森林基尼指数的特征优选方法。分析涵盖了9个光谱波段特征、9个植被指数、4个纹理特征和3个地形特征，共计25个分类特征。其中光谱波段特征选取9个常用于作物分类的波段特征：蓝光波段(B2)、绿光波段(B3)、红光波段(B4)、红边1波段(B5)、红边2波段(B6)、红边3波段(B7)、近红外波段(B8)、短波红外1波段(B11)和短波红外2波段(B12)。纹理特征选择4个主要纹理特征：角二阶矩(ASM)、对比度(CONTRAST)、相关性(CORRELATION)和熵(ENTROPY)。地形特征选择海拔高度(ELEVATION)、坡度(SLOPE)和坡向(ASPECT)。表3为所选取的植被指数特征计算公式。

表3 植被指数特征计算公式

Tab.3 Vegetation index feature calculation formula

统计量	表达公式	参考文献
归一化差值植被指数	$NDVI=\frac{B_8-B_4}{B_8+B_4}$	[31]
差值植被指数	$DVI=B_8-B_4$	[32]
植被红边指数	$RVI=\frac{B_8}{B_4}$	[33]
土壤调节植被指数	$SAVI=\frac{1.5(B_8-B_4)}{B_8+B_4+1.5}$	[34]
增强型植被指数	$EVI=2.5\frac{B_8-B_4}{B_8+6B_4+7.5B_2+1}$	[35]
归一化水体指数	$NDWI=\frac{B_3-B_8}{B_3+B_8}$	[36]
归一化建筑物指数	$NDBI=\frac{B_{11}-B_8}{B_{11}+B_8}$	[37]
红边叶绿素指数	$CIRE=\frac{B_7}{B_5}-1$	[38]
红边位置指数	$S2REP=705+35\frac{\frac{B_4+B_7}{2}-B_5}{B_6-B_5}$	[39]

结果表明，当特征数量为15时，分类精度达到最高。基于这一结果，选择前15个最重要特征，包括DVI、NDWI、B2、NDVI、B12、RVI、ELEVATION、SAVI、B8、B3、B11、CIRE、B5、SLOPE和CONTRAST，作为优选特征数据集，以优化模型的总体性能。特征重要性得分如图6所示，特征数量与总体精度的关系如图7所示。

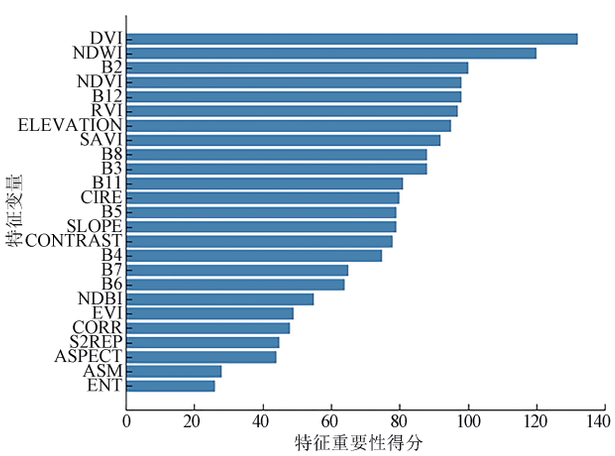

图6 分类特征重要性排序图

Fig. 6 Importance ranking chart for categorical features

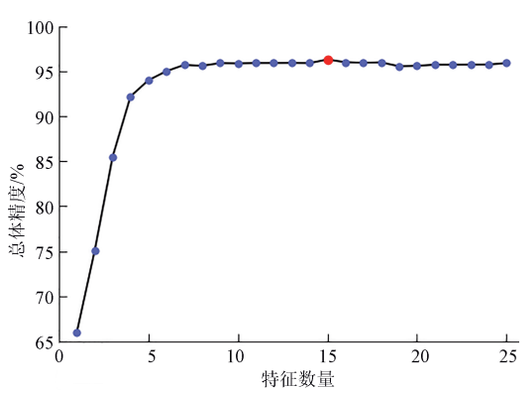

图7 特征数量与总体精度的关系

Fig. 7 Number of features versus overall accuracy

在排序之后，采用基于特征重要性的后向消除方法对特征集进行降维处理，选择了精度最高的子集作为最优特征数据集。这种方法帮助有效地筛选出对模型性能影响最大的特征。

3.3 不同模型分类精度比较

3.3.1 实验环境

在由Python编程语言驱动的环境下进行，利用PyTorch作为主要的深度学习库来构建和训练CNN-LSTM模型。表4为实验所依赖的硬件和软件配置。

表4 CNN-LSTM模型实验环境

Tab.4 CNN-LSTM model experimental environment

类别	配置
硬件	CPU：Intel Core i7-8700k，3.70 GHz，32 GB
	GPU: NVIDIA GeForce GTX 1070
	内存：8 GB
	硬盘：1 TB
软件	操作系统：Windows 10
	编程语言：Python 3.7
	深度学习框架：PyTorch 1.21.1

3.3.2 不同时间序列长度分类精度对比

分别将扩充前的Sentinel-2影像数据和利用ESTARFM时空融合算法扩充后的时间序列影像数据输入训练后的LSTM模型，进行研究区域不同地物的分类，验证时间序列长度对分类结果的影响，如表5所示。

表5 不同时间序列长度精度统计

Tab.5 Accuracy statistics for different time series lengths

时间序列长度	OA/%	Kappa系数	F1值/%	MIoU
扩充前	93.97	0.917 5	90.63	0.848 9
扩充后	95.87	0.943 8	94.52	0.884 3

从表5可以看出，使用完整时间序列作为输入的LSTM模型总体精度（OA）和Kappa系数分别为95.87%和0.943 8，比扩充前总体精度提高1.9个百分点，Kappa系数提高0.026 3。证明利用ESTARFM算法扩充因云雨天气导致的Sentinel-2影像的缺失，构建长时间序列数据集的有效性。并且扩充前时间序列总体精度93.97%，大于基于农作物生长关键期的单期或少期影像精度93.85%，从而验证了时间序列特征有利于分类精度的提升。

将不同时期的时序影像依次加入至CNN-LSTM模型中进行训练，探究随着苹果物候期增加和影像时间序列的扩展，CNN-LSTM模型对其种植区域的分类效果，如表6所示。

由表6可以看出模型在果实膨大期阶段预测精度达到96.34%，Kappa系数达到0.951 2，证明模型在果实膨大期便能够实现高精度的苹果树种植区域提取。同时，随着苹果的成熟，整体的精度提高。原因在于随着果实的成熟，苹果树的叶面积逐渐增大，植被覆盖率提高。当苹果树的叶片逐渐覆盖更多地表时，模型可以更准确

地识别苹果树种植区域。随着时间序列的扩展，苹果生长过程中光谱特征和植被指数的动态变化也逐渐显现，为模型提供了更丰富的特征信息。深度学习模型通过学习这些时序变化，能够更准确地识别和提取苹果树种植区域。

表6　不同苹果物候期模型分类精度

Tab.6　Observation records of apple phenology data

物候期	OA/%	Kappa系数
萌芽期	63.58	0.605 3
花期	75.24	0.712 7
幼果期	85.71	0.843 9
果实膨大期	96.34	0.951 2
着色成熟期	97.98	0.958 6

3.3.3　CNN-LSTM模型与几种常见模型分类精度比较

将扩充后完整时间序列影像数据分别输入LSTM模型和改进CNN-LSTM模型，并与4种常用的机器学习模型进行对比，验证分类算法有有效性。图8为不同分类算法下时间序列遥感作物分类。

如图8所示，传统分类方法如CART、SVM、RF及GBDT在本研究中表现出较差的泛化能力。在具体案例分析中，观察到这些方法在处理苹果林边界区域时，因相似像元的存在，容易将苹果林与其他树木错误地合并为同一影像对象。这种合并现象导致了分类结果的不精确，尤其是在细节提取方面的不足，从而增加了错分的可能性。此外，这些方法在分类过程中也未能有效避免“椒盐噪声”的产生，进一步影响了分类结果的可靠性。

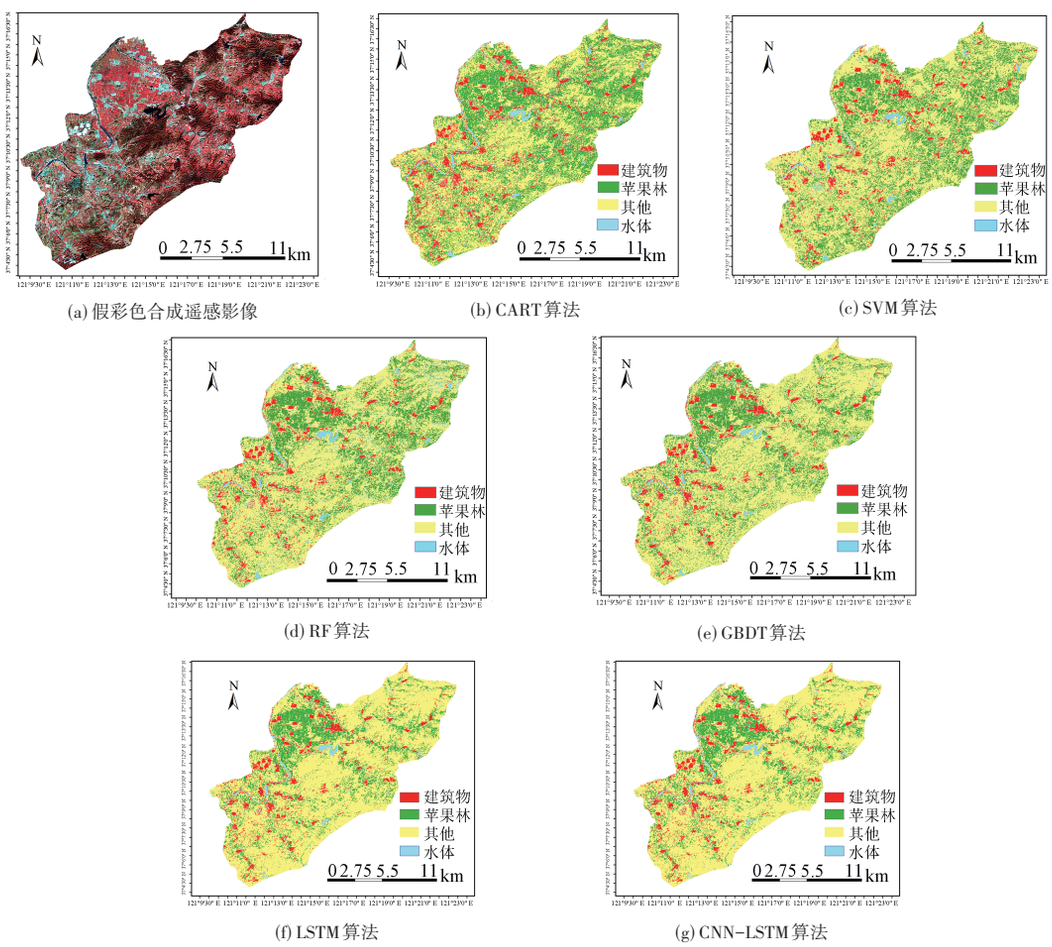

(a) 假彩色合成遥感影像　(b) CART算法　(c) SVM算法

(d) RF算法　(e) GBDT算法

(f) LSTM算法　(g) CNN-LSTM算法

图8　不同分类算法分类结果对比

Fig. 8　Comparison of classification results of different classification algorithms

采用LSTM时序模型和CNN-LSTM时空谱模型的方法因考虑到了时序特征，显示出较高的分类精度和一致性。这些模型通过整合时间序列数据，能够更细致地捕捉到作物生长周期中的光谱变化，从而显著减少分类误差。特别是时序模型在减少分类过程中的“椒盐噪声”方面表现尤为突出，有效提高了分类结果的整体质量。为了进一步定量评价这些不同分类方法的效果，本研究使用了验证样本数据进行了精度评估。精度评估结果将为不同模型的性能比较提供定量依据，从而帮助识别哪些模型在实际应用中可能表现更优越。通过这种方式，能够更准确地理解不同分类模型在处理复杂农业景观时的优势与限制，为未来的研究与应用提供重要的参考信息。具体计算结果见表7。

由表7可知，CNN-LSTM模型总体精度为97.98%，Kappa系数为0.958 6，与LSTM模型总体精度和Kappa系数相比分别提高2.11个百分点和0.014 8，总体精度对比其他4种机器学习算法分别高15.43、5.25、4、3.31个百分

表7 不同模型分类精度

Tab.7 Accuracy statistics for different time series lengths

方法	OA/%	Kappa系数	F1值/%	MIoU
CART	82.55	0.763 5	80.36	0.722 7
SVM	92.73	0.898 7	88.51	0.773 4
RF	93.98	0.913 2	89.62	0.803 4
GBDT	94.67	0.923 6	90.27	0.824 6
LSTM	95.87	0.943 8	94.52	0.848 9
CNN-LSTM	97.98	0.958 6	97.73	0.903 1

点,Kappa系数分别比其他4种机器学习算法高0.191 5、0.059 9、0.045 4、0.035,其余两个指标也是CNN-LSTM算法最高。实验结果证明了基于深度学习CNN-LSTM算法利用时空谱特征进行苹果树种植区域提取的有效性。多时相影像增加了数据的维度,可以通过时间序列分析来提取时间维度上的特征,例如作物的生长速度、生长周期的长度等,这些都是单时相影像难以提供的信息。

4 结论

(1)提出了一种改进的CNN-LSTM模型使用Sentinel-2和MODIS融合影像时间序列进行苹果树种植区域的提取。通过将该方法与其他分类算法对比,证明本研究所提出的模型在苹果树种植区域的提取方面更加精准。

(2)使用ESTARFM时空融合算法扩充因云雨天气导致的Sentinel-2影像的缺失,构建长时间序列数据集。使用LSTM模型训练扩充后时间序列影像输入训练,总体精度较使用扩充前时间序列影像提高1.9个百分点,达到95.87%。Kappa系数提高0.026 3,达到0.943 8。

(3)基于随机森林基尼指数的特征优选方法进行最优特征集的构建。当特征数量为15时,分类精度达到最高。对25个特征进行重要性排序后采用基于特征重要性的后向消除方法对特征集进行降维处理,选择了精度最高的子集作为最优特征数据集。

(4)基于CNN-LSTM模型,在空间-光谱波段特征增强阶段,采用了一种混合的3D与2D卷积神经网络架构并进一步整合了LSTM网络,以获得结合时间、空间和光谱维度的深层特征。改进的CNN-LSTM模型总体精度为97.98%,Kappa系数为0.958 6。与LSTM模型总体精度和Kappa系数相比分别提高2.11个百分点和0.014 8。

参 考 文 献

[1] 刘晓丽. 浅析庆阳苹果的营养价值与保健作用[J]. 甘肃科技, 2018,34(21):159-160.

[2] 杨杰. 重新认识山东在全国苹果产业中的战略地位[J]. 果农之友, 2023(6):105-106.

[3] 张强强,霍学喜,刘军弟,等. 世界苹果产销格局及市场动态预测分析[J]. 世界农业, 2016(7):147-152.

[4] 王秋萍. 山东:烟台苹果蝉联中国果业第一品牌[J]. 中国果业信息, 2023,40(11):55.

[5] MASSEY R, SANKEY T T, CONGALTON R G, et al. MODIS phenology-derived, multi-year distribution of conterminous U.S. crop types[J]. Remote Sensing of Environment, 2017,198:490-503.

[6] DA SILVA M R, DE CARVALHO O A, GUIMARAES R F, et al. Wheat planted area detection from the MODIS NDVI time series classification using the nearest neighbour method calculated by the Euclidean distance and cosine similarity measures[J]. Geocarto International 2020,35(13):1400-1414.

[7] YANG R, AHMED Z U, SCHULTHESS U C, et al. Detecting functional field units from satellite images in smallholder farming systems using a deep learning based computer vision approach: a case study from Bangladesh[J]. Remote Sensing Applications : Society and Environment, 2020,20:100413.

[8] CHU L, JIANG C, WANG T, et al. Mapping and forecasting of rice cropping systems in central China using multiple data sources and phenology-based time-series similarity measurement[J]. Advances in Space Research, 2021,68(9):3594-3609.

[9] ZHONG L, YU L, LI X, et al. Rapid corn and soybean mapping in US Corn Belt and neighboring areas[J]. Scientific Reports, 2016,6:36240.

[10] HUANG Y, LIU X, LI X, et al. Comparing the effects of temporal features derived from synthetic time-series NDVI on fine land cover classification[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2018,11(12):4618-4629.

[11] PELLETIER C, VALERO S, INGLADA J, et al. Assessing the robustness of random forests to map land cover with high resolution satellite image time series over large areas[J]. Remote Sensing of Environment, 2016,187:156-168.

[12] SHEYKHMOUSA M, MAHDIANPARI M, GHANBARI H, et al. Support vector machine versus random forest for remote sensing image classification: a meta-analysis and systematic review[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2020,13:6308-6325.

[13] LI Q, TIAN J, TIAN Q. Deep learning application for crop classification via multi-temporal remote sensing images[J]. Agriculture, 2023,13(4):906.

[14] JAMALI A, MAHDIANPARI M. Swin transformer and deep convolutional neural networks for coastal wetland classification using Sentinel-1, Sentinel-2, and LiDAR Data[J]. Remote Sensing (Basel, Switzerland), 2022,14(2):359.

[15] LIN Z, ZHONG R, XIONG X, et al. Large-scale rice mapping using multi-task spatiotemporal deep learning and Sentinel-1 sar time series[J]. Remote Sensing, 2022,14(3):699.

[16] CHEN B, ZHENG H, WANG L, et al. A joint learning Im-BiLSTM model for incomplete time-series Sentinel-2A data imputation and crop classification[J]. International Journal of Applied Earth Observation and Geoinformation, 2022,108:102762.

[17] CAMPOS-TABERNER M, GARCÍA-HARO F J, MARTÍNEZ B, et al. Understanding deep learning in land use classification based on Sentinel-2 time series[J]. Scientific Reports, 2020,10(1):17188.

[18] 吴庆双,汪明秀,申茜,等. Sentinel-2遥感图像的细小水体提取[J]. 遥感学报, 2022,26(4):781-794.
WU Qingshuang, WANG Mingxiu, SHEN Qian, et al. Small water body extraction method based on Sentinel-2 satellite multi-spectral remote sensing image[J].National Remote Sensing Bulletin, 2022,26(4):781-794.(in Chinese)
[19] 张磊,宫兆宁,王启为,等. Sentinel-2影像多特征优选的黄河三角洲湿地信息提取[J]. 遥感学报, 2019,23(2):313-326.
ZHANG Lei, GONG Zhaoning, WANG Qiwei, et al. Wetland mapping of Yellow River Delta wetlands based on multi-feature optimization of Sentinel-2 images[J].National Remote Sensing Bulletin, 2019,23(2):313-326.(in Chinese)
[20] 祁向前,孙德浩,贾连星. 哨兵2号多时相植被指数作物分类及监测[J]. 测绘工程, 2022,31(6):47-53.
QI Xiangqian, SUN Dehao, JIA Lianxing. Sentinel-2 multi-temporal vegetation index crop classification and monitoring [J].Engineering of Surveying and Mapping, 2022,31(6):47-53.(in Chinese)
[21] 易扬,胡昕利,史明昌,等. 基于MODIS NDVI的长江中游区域植被动态及与气候因子的关系[J]. 生态学报, 2021,41(19):7796-7807.
YI Yang, HU Xinli, SHI Mingchang, et al. Vegetation dynamics and its relationship with climate factors in the middle reaches of the Yangtze River based on MODIS NDVI[J]. Acta Ecologica Sinica, 2021,41(19):7796-7807.(in Chinese)
[22] 殷崎栋,柳彩霞,田野. 基于MODIS NDVI数据的陕西省植被绿度时空变化及人类活动影响[J]. 生态学报, 2021,41(4):1571-1582.
YIN Qidong, LIU Caixia, TIAN Ye. Spatio-temporal greenness and anthropogenic analysis in Shaanxi based on MODIS NDVI from 2001 to 2018[J]. Acta Ecologica Sinica, 2021,41(4):1571-1582.(in Chinese)
[23] ROSTAMI A, RAEINI-SARJAZ M, CHABOKPOUR J, et al. Soil moisture monitoring by downscaling of remote sensing products using LST/VI space derived from MODIS products[J]. Water Supply, 2023,23(2):688-705.
[24] 郝斌飞,韩旭军,马明国,等. Google Earth Engine在地球科学与环境科学中的应用研究进展[J]. 遥感技术与应用, 2018,33(4):600-611.
HAO Binfei, HAN Xujun, MA Mingguo, et al. Research progress on the application of Google Earth Engine in geoscience and environmental sciences[J]. Remote Sensing Technology and Application, 2018,33(4):600-611.(in Chinese)
[25] 林蕾. 基于循环神经网络模型的遥感影像时间序列分类及变化检测方法研究[D]. 北京:中国科学院大学(中国科学院遥感与数字地球研究所), 2018.
LIN Lei. Satellite image time series classification and change detection based on recurrent neural network model[D].Beijing: University of Chinese Academy of Sciences(Institute of Remote Sensing and Digital Earth, Chinese Academy of Sciences), 2018.(in Chinese)
[26] ZHU X, CHEN J, GAO F, et al. An enhanced spatial and temporal adaptive reflectance fusion model for complex heterogeneous regions[J]. Remote Sensing of Environment, 2010,114(11):2610-2623.
[27] 李昊勋,郑宏刚,刘淑霞,等. 基于随机森林下的云南省耕地利用效率测算及基尼系数分析[J]. 湖北农业科学, 2023,62(7):32-37.
LI Haoxun,ZHENG Honggang,LIU Shuxia, et al. Calculation of cultivated land utilization efficiency and analysis of Gini coefficient in Yunnan Province based on random forest[J]. Hubei Agricultural Sciences, 2023,62(7):32-37.(in Chinese)
[28] 张悦琦,任鸿瑞. 融合特征优选与随机森林算法的GF-6影像东北一季稻遥感提取[J]. 遥感学报, 2023,27(9):2153-2164.
ZHANG Yueqi, REN Hongrui. Remote sensing extraction of paddy rice in Northeast China from GF-6 images by combining feature optimization and random forest[J]. National Remote Sensing Bulletin, 2023,27(9):2153-2164.(in Chinese)
[29] 梁美静,毛克彪,郭中华,等. 深度学习在农业领域的研究与应用[J]. 农业工程, 2024,14(1):30-36.
[30] 解毅,张永清,荀兰,等. 基于多源遥感数据融合和LSTM算法的作物分类研究[J]. 农业工程学报, 2019,35(15):129-137.
[31] HUANG S, TANG L, HUPY J P, et al. A commentary review on the use of normalized difference vegetation index (NDVI) in the era of popular remote sensing[J]. Journal of Forestry Research, 2021,32(1):1-6.
[32] YAN K, GAO S, CHI H, et al. Evaluation of the vegetation-index-based dimidiate pixel model for fractional vegetation cover estimation[J]. IEEE Transactions on Geoscience and Remote Sensing, 2021,60:1-14.
[33] KROSS A, MCNAIRN H, LAPEN D, et al. Assessment of RapidEye vegetation indices for estimation of leaf area index and biomass in corn and soybean crops[J]. International Journal of Applied Earth Observation and Geoinformation, 2015,34:235-248.
[34] HUETE A R. A soil-adjusted vegetation index (SAVI)[J]. Remote Sensing of Environment, 1988,25(3):295-309.
[35] MATSUSHITA B, YANG W, CHEN J, et al. Sensitivity of the enhanced vegetation index (EVI) and normalized difference vegetation index (NDVI) to topographic effects: a case study in high-density cypress forest[J]. Sensors, 2007,7(11):2636-2651.
[36] GAO B C. NDWI—a normalized difference water index for remote sensing of vegetation liquid water from space[J]. Remote Sensing of Environment, 1996,58(3):257-266.
[37] ZHA Y, GAO J, NI S. Use of normalized difference built-up index in automatically mapping urban areas from TM imagery[J]. International Journal of Remote Sensing, 2003,24(3):583-594.
[38] XIE Q, DASH J, HUANG W. Vegetation indices combining the red and red-edge spectral information for leaf area index retrieval[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2018,11(5):1482-1493.
[39] IMRAN A B, KHAN K, ALI N, et al. Narrow band based and broadband derived vegetation indices using Sentinel-2 imagery to estimate vegetation biomass[J]. Global Journal of Environmental Science and Management, 2020,6(1):97-108.