doi:10.6041/j.issn.1000-1298.2025.02.034

基于客观赋权法和集成学习的作物遥感分类研究

荀　兰　解　毅
(山西师范大学地理科学学院, 太原 030031)

摘要: 不同作物遥感分类算法具备不同的学习能力和容错能力,单一分类器的精度因研究区和使用的数据不同而存在差异,没有一种分类器能够在所有情况下都获得最优表现。鉴于此,本文提出了基于客观赋权法集成多分类器的集成学习算法用于作物分类。以 K 最近邻法、支持向量机、随机森林、BP 神经网络和一维卷积神经网络为基分类器,基于 Sentinel-2 多光谱影像计算时序归一化植被指数(Normalized difference vegetation index,NDVI)作为输入特征。对熵值法和变异系数法进行改进,并结合组合赋权法对 5 个基分类器进行加权集成。结果表明,利用改进的赋权方法确定基分类器的权重获得的分类精度高于利用原始赋权方法,并且基于组合赋权法对改进的熵值法和改进的变异系数法进行组合获得的分类精度略高于基于单一赋权方法获得的分类精度。与基分类器相比,基于 F1 值和归一化组合赋权法构建的集成学习算法在美国阿肯色州、佐治亚州、得克萨斯州和爱荷华州 4 个研究区的分类总体精度分别提高 1.12~6.45、0.75~3.98、0.45~2.70、1.15~2.50 个百分点。与传统众数投票、概率融合和精度加权方法相比,本文提出的集成学习算法同时考虑了基分类器精度差异与稳定性。

关键词: 遥感; 作物分类; 集成学习; 客观赋权法
中图分类号: S127　　**文献标识码**: A　　**文章编号**: 1000-1298(2025)02-0370-11　　**OSID**:

Remote Sensing Crop Classification Based on Objective Weighting Method and Ensemble Learning

XUN Lan　XIE Yi
(*College of Geographical Sciences*, *Shanxi Normal University*, *Taiyuan* 030031, *China*)

Abstract: Accurate crop map is critical for agricultural monitoring and related decision-making. Although many algorithms were adopted for crop classification, the performance of individual classifier varied with study area and data used. Aiming to address this issue, a novel ensemble learning (EL) framework was developed, which adopted objective weighting methods to assign weights to five widely used classifiers, including K-nearest neighbor, support vector machine, random forest, back propagation neural network and convolutional neural network. Four study sites in the United States were selected to examine the performance of the proposed EL framework. Time series of normalized difference vegetation index derived from Sentinel-2 multispectral instrument images were used as the input features for crop classification. Two modified objective weighting methods, termed modified entropy method (mEN) and modified coefficient of variation method (mCV), were proposed to determine the weights of base classifiers. The probability outputs of base classifiers were combined with weights to determine the final label. The results showed that weights assigned by modified weighting methods were more reasonable than those by original weighting methods in multi-classifier ensemble. The combination of mEN and mCV (mEN-mCV) further amplified the weight difference of base classifiers, and achieved an improved performance than single weighting method. Compared with five base classifiers, overall accuracy achieved by mEN-mCV with F1-score as input (mEN-mCV-F) was increased by 1.12~6.45 percentage points, 0.75~3.98 percentage points, 0.45~2.70 percentage points and 1.15~2.50 percentage points at four sites, respectively. The advantage of the proposed EL framework over unweighted (i.e., majority vote, probability fusion) and accuracy-weighted methods was that both classification accuracy

收稿日期: 2024-09-28　修回日期: 2024-10-23
基金项目: 山西省基础研究计划项目(202303021212157、202303021221149)
作者简介: 荀兰(1995—),女,讲师,主要从事农业遥感研究,E-mail: xunlan@sxnu.edu.cn
通信作者: 解毅(1989—),男,副教授,主要从事农业遥感研究,E-mail: xieyi@sxnu.edu.cn

and stability of base classifiers were considered, thus resulting in a higher performance. These results indicated that the proposed EL framework had potential in improving the accuracy of crop classification.
Key words: remote sensing; crop classification; ensemble learning; objective weighting method

0　引言

及时、准确的作物分布图是作物生长状况监测、产量估算、农业政策制定等诸多应用的前提[1-3]。卫星遥感具有覆盖范围广、数据获取及时、动态更新快等优势,已成为监测作物空间分布信息的重要手段[4-5]。

近年来,已有多种传统机器学习和深度学习算法被应用于作物遥感分类研究[6-7]。然而,不同算法具备不同的学习能力和容错能力,没有一种算法能够在所有场景下都能获得最优表现[8]。集成学习(Ensemble learning, EL)通过使用某种策略整合多个分类器进行类别决策,在提高图像分类精度方面具有很大的潜力。序列集成和并行集成是两类常用的集成学习策略。并行集成利用一定的规则将不同分类器的结果进行组合,每个分类器被独立训练且决策过程不受其他分类器的影响,该结构的灵活性较好且应用较为广泛,常用的规则有众数投票、概率融合和 Stacking[9]。众数投票基于少数服从多数的思想,将待识别样本的类别定义为多数分类器具有相同决策的类别。概率融合将每个分类器对应于每个类别的概率进行组合,将待识别样本划分为融合概率最高的类别。在传统的众数投票和概率融合方法中,每个基分类器都具有相同的权重,忽略了不同基分类器自身分类性能的差异[10]。为了将该差异融入到集成学习策略中,一些研究在众数投票和概率融合时根据不同分类器的性能对基分类器赋予不同的权值,研究结果表明,加权集成获得的结果通常更优[11]。SHEN 等[12]以最大似然法、光谱角法、最小距离法、马氏距离法和光谱信息差异法为基分类器,分别利用生产者精度、总体精度以及二者的乘积作为权重值对基分类器进行加权集成,结果表明,以生产者精度作为权重值获得的分类精度优于以总体精度作为权重值获得的分类精度。然而,直接利用基分类器的精度指标作为权重值构建的集成学习算法忽略了不同基分类器的稳定性差异。

主观赋权法和客观赋权法常被用于确定多个指标的权重。主观赋权法是由决策者根据经验判断决定各指标的重要程度,从而对不同指标分配权重,该方法充分反映了决策者的意向,如因子权重排序法、层次分析法等。然而,其评价结果具有较大的主观性。客观赋权法根据数据与数据之间的关系结合数学方法对不同指标分配权重,赋权过程中不考虑决策者的偏好,得到的评判结果的数学理论依据较强[13-14]。例如,熵值法和变异系数法分别根据指标的离散程度和变异程度进行权重分配,这两种方法的思想是对离散程度或变异程度较大的指标分配较高的权重[15-16]。然而,若在多次实验中基分类器的精度差异较大,说明该分类器是不稳定的,在集成学习过程中应该给予较低的权重。因此,这两种客观赋权方法可能不适合直接用于基分类器权重的确定。

本文对 2 种客观赋权方法进行改进,提出改进的熵值法和改进的变异系数法,以 K 最近邻法、支持向量机、随机森林、BP 神经网络和一维卷积神经网络为基分类器,利用改进的赋权方法对基分类器进行加权集成以构建集成学习算法,利用该算法开展作物分类研究,并与基分类器及其他集成学习算法进行精度对比。

1　研究区和数据

1.1　研究区概况

在美国阿肯色州、佐治亚州、德克萨斯州和爱荷华州选取 4 个研究区。考虑到作物比例和样本数据质量,在每个研究区选择不同的目标作物类型。研究区 A 位于阿肯色州东北部,该区域土地肥沃,作物类型丰富,目标作物为大豆、棉花、水稻、玉米和花生。以该区域为例,构建集成学习算法并测试其有效性,将其他 3 个研究区作为算法应用区域,测试算法的稳定性。研究区 B 位于佐治亚州南部,目标作物为棉花、花生和玉米。此外,为了检验所提出的算法在识别单一作物类型中的表现,研究区 C 和研究区 D 分别位于德克萨斯州和爱荷华州,这 2 个州分别是美国最大的棉花生产州和玉米生产州,目标作物分别为棉花和玉米。4 个研究区所有目标作物的生育期主要集中于 4—11 月。除了每个研究区的目标作物外,其他作物被归为一类。研究区域和目标作物类型样本位置分布如图 1 所示。

1.2　数据来源及预处理

1.2.1　遥感数据及预处理

本文使用 Sentinel - 2 多光谱(Multispectral instrument, MSI)影像开展作物分类。在 Google Earth Engine(GEE)云平台筛选研究区 4—11 月云量少于 50% 的地表反射率影像并进行预处理。4 个

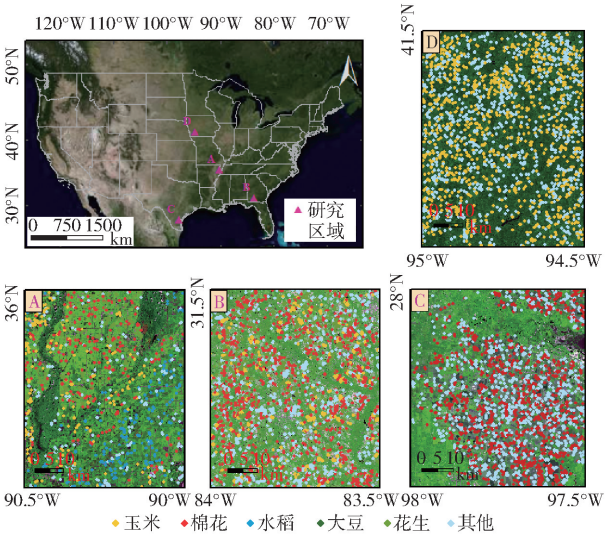

图 1 研究区域及样点分布

Fig. 1 Locations of study sites and samples

研究区分别利用 2019、2019、2020、2022 年的影像，影像数量分别为 91、68、255、190 景。利用最近邻法将 QA60 波段重采样为 10 m，进而对影像有云区域进行掩膜处理。为了能够完整覆盖每个研究区，需要多个轨道的遥感数据，由于不同轨道的遥感数据可能存在一定程度的重叠，导致不同像素的影像观测数量不同。此外，云覆盖和云掩膜也会导致不同像素观测数据的时间间隔不一致。因此，对研究区数据进行 15 d 中值合成处理。此外，在一些区域，由于云或其他因素的影响，在某些时段可能无法获得高质量的观测结果，利用该时段前后的高质量观测数据进行线性插值处理[17]。由于多分类器集成是本研究的主要目标，因此未进行特征优选。本文利用时间序列归一化植被指数（Normalized difference vegetation index，NDVI）作为分类器输入特征，该特征已被广泛应用于作物分类[18]。

1.2.2 样本数据

将 Cropland Data Layer（CDL）数据作为作物样本数据选取的参考依据，该数据是由美国农业部（United States Department of Agriculture，USDA）基于中空间分辨率的卫星影像和广泛的农业地面调查生成的包含具体作物类型的栅格图层，空间分辨率为 30 m，常被应用于作物分类研究的参考数据[19]。CDL 数据包含耕地层、作物层和置信度层。作物层包括了具体的类别标签。置信度层反映每个像素标签可信度，取值范围为 0 ~ 100%，置信度越大表示标签可信度越高。从 GEE 云平台获取覆盖研究区的 CDL 数据，并将其重采样为 10 m。利用耕地层对研究区的非耕地区域进行掩膜处理。为了避免 CDL 数据自身误差的影响，同时为了避免样本选择对数据分析的影响，参考耕地层、作物层和置信度层，从置信度高于 90% 的区域随机生成多组作物样本用于后续数据分析、分类器的训练及精度检验等。

2 研究方法

本文的技术路线如图 2 所示。首先，基于作物生长季的 Sentinel－2 MSI 影像构建时间序列 NDVI 作为不同作物分类的输入特征。然后，基于基分类器和赋权方法构建集成学习算法，该算法主要包括：①分别对 5 个基分类器进行训练并对训练精度进行评价。②对熵值法和变异系数法进行改进，分别利用改进的赋权方法及组合赋权法确定每个基分类器的权重。③结合 5 个基分类器的概率输出和权重进行决策融合，从而确定最终的类别标签。最后，对不

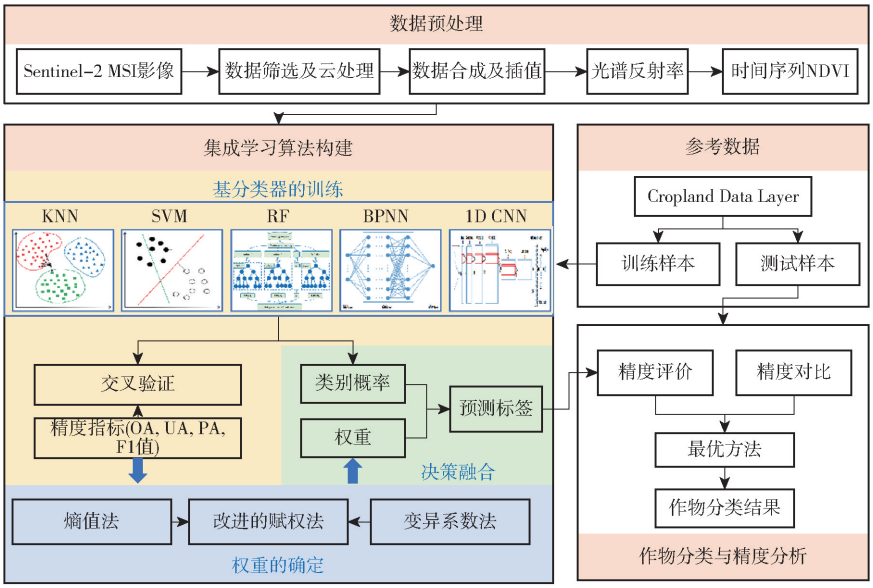

图 2 技术路线图

Fig. 2 Flowchart of study

同赋权方法及不同集成策略获得的分类精度进行评价和比较。

2.1　基分类器训练

2.1.1　K 最近邻法

作为一种简单的机器学习算法，K 最近邻法（K-nearest neighbor，KNN）的基本思想是每个样本可以用其最近邻的 K 个样本来表示。若特征空间中一个样本的 K 个最近邻样本中的大部分样本都属于某一类别，则该样本也被定义为同样类别[20]。本文通过多次实验将 K 设置为 7。

2.1.2　支持向量机

支持向量机（Support vector machine，SVM）是一种基于统计学习理论的非参数监督分类方法，它通常在解决非线性问题、有限数量的训练样本处理以及高维数据处理等方面都具有优势[21]。高斯核函数在遥感图像分类中具有较好的表现，本研究选取其作为核函数，其余参数采用 Matlab 软件中的默认参数值。

2.1.3　随机森林

随机森林（Random forest，RF）是由多棵决策树组成的 Bagging 集成算法，通过投票得出最终的预测结果[22-23]。相较于传统的决策树方法，随机森林的鲁棒性较好，抗噪能力强，有能力处理特征维度高的数据。本文将决策树的数量（ntree）设定为 500，每个节点上可用于分割的特征数量（mtry）使用默认值，即输入变量数量的平方根。

2.1.4　BP 神经网络

作为一种广泛使用的人工神经网络，BP 神经网络（Back propagation neural network，BPNN）是一种多层前馈神经网络，其特点是信号正向传播而误差反向传播[24]。BP 神经网络一般由输入层、隐含层和输出层组成，其基本思想是通过计算实际输出值与期望输出值之间的误差来调整参数以提高精度[20]。本研究构建的 BP 神经网络包括 1 个输入层、10 个隐含层和 1 个输出层。选取“trainlm”作为训练函数，利用 Levenberg－Marquardt 算法对 BP 神经网络进行训练，迭代次数设置为 1 000，学习目标设置为 0.000 1，其余参数的设置使用 Matlab 软件中函数参数设置的默认值。

2.1.5　一维卷积神经网络

卷积神经网络（Convolutional neural network，CNN）是一种局部连接、权值共享的前馈式多层神经网络。一维卷积神经网络（One-dimensional convolutional neural network，1D CNN）是 CNN 的一种特殊形式，一维卷积核被用于对输入序列的时间模式进行捕获。本研究以时间序列 NDVI 作为输入数据，构建用于作物分类的 1D CNN 框架如图 3 所示，包括输入层、卷积层、池化层、全连接层、Softmax 层和分类输出层。其中，卷积层的数量为 4 个，其余层的数量各为 1 个。4 个卷积层的卷积核大小分别为 1×3×8、1×3×16、1×3×32 和 1×3×32，卷积步长为 1，激活函数为 ReLU。池化层的卷积核大小为 1×2，采用 max-pooling 操作，卷积步长为 2，全连接层大小为 1×256。

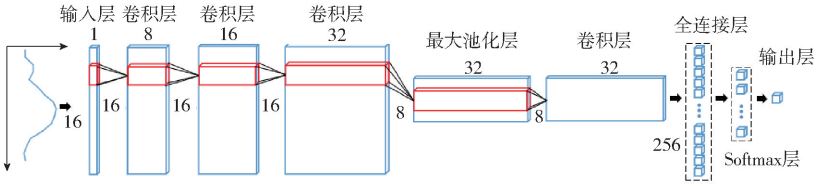

图 3　本文用于作物分类的 1D CNN 结构

Fig. 3　Architecture of 1D CNN adopted for crop classification

2.1.6　训练精度评价方法

在 CDL 数据置信度值高于 90% 的区域，每个类别随机选取 200 个训练样本分别对 5 个基分类器进行训练。利用重复 K 折交叉验证评价基分类器的训练精度[25]。将所有训练样本随机分为 K 组，其中，选取 $K-1$ 组用于训练基分类器，剩余 1 组作为验证样本评估基分类器的训练精度，将该过程重复 K 次，最后对 K 次的验证结果进行整合，计算获得 1 组分类精度指标，包括总体精度、F1 值、生产者精度和用户精度。本文将 K 设置为 10，然后将 K 折交叉验证过程再重复 10 次，得到 10 组训练精度作为基分类器评价指标，进而作为赋权方法的输入用于确定基分类器权重。

2.2　权重确定方法

2.2.1　改进的熵值法

熵值法依据每个指标的观测数据所提供的信息量进行指标权重确定[15]。指标的离散程度越大，意味着在综合评价中该指标的影响越大，其熵值越小，该指标所提供的有效信息量越大，因此，赋予权重也越大；反之，熵值越大，赋予权重越小[26]。在多分类器集成学习中，当分类器精度离散程度较大时，熵值较小，意味着分类器稳定性较差，应给予较低的权重；反之，意味着分类器稳定性较好，应给予较高的权重。

因此,基于熵值法(Entropy method,EN)计算的权重,提出了一种改进的熵值法(modified entropy method,mEN)来确定 5 个基分类器的权重,具体计算步骤为:

以 5 个基分类器的训练精度作为输入数据,构建矩阵 $\boldsymbol{A}=(a_{ij})_{m\times n}$。其中,$a_{ij}(i=1,2,\cdots,m;j=1,2,\cdots,n)$表示第 j 个基分类器的第 i 个精度指标。m 和 n 分别表示精度指标和基分类器的数量,本文 n 取 5。第 i 个精度指标对应的第 j 个基分类器的比重 y_{ij}为

$$y_{ij}=\frac{a_{ij}}{\sum_{i=1}^{m}a_{ij}} \tag{1}$$

计算第 j 个基分类器的熵值 e_j

$$e_j=-k\sum_{i=1}^{m}y_{ij}\ln y_{ij} \tag{2}$$

其中 $$k=1/\ln m$$

利用熵值法计算的权重为

$$w_j=\frac{1-e_j}{\sum_{j=1}^{n}(1-e_j)} \tag{3}$$

其中 $$\sum_{j=1}^{n}w_j=1$$

式中 w_j——第 j 个基分类器权重,取0 ~ 1

本文提出改进的熵值法,通过归一化$(1-w_j)$作为基分类器的权重

$$w_j'=\frac{1-w_j}{\sum_{j=1}^{n}(1-w_j)} \tag{4}$$

其中 $$\sum_{j=1}^{n}w_j'=1$$

式中 w_j'——第 j 个基分类器权重归一化值,取 0 ~ 1

2.2.2 改进的变异系数法

变异系数可以用来描述和衡量变量的不确定性,并且具有独立于先验主观假设的优点。本文利用变异系数来度量基分类器训练精度的变异程度。变异系数的计算方式为[16]

$$V_j=S_j/M_j\quad(j=1,2,\cdots,n) \tag{5}$$

式中 V_j——变异系数

S_j——多组数据标准差

M_j——多组数据均值

本文提出改进的变异系数法(modified coefficient of variation,mCV),通过归一化的 $1/V_j$ 来确定基分类器权重,计算方式为

$$w_j'=\frac{1/V_j}{\sum_{j=1}^{n}1/V_j} \tag{6}$$

2.2.3 归一化组合赋权法

归一化组合赋权法将不同赋权方法得到的权重进行组合,该方法计算方式简单,应用较为广泛,具体计算公式为

$$w_{cj}=\frac{w_j^1w_j^2}{\sum_{j=1}^{n}w_j^1w_j^2} \tag{7}$$

式中 w_{cj}——第 j 个基分类器组合权重

w_j^1、w_j^2——利用 2 种赋权方法分配给第 j 个基分类器的权重

利用归一化组合赋权法将改进的熵值法和改进的变异系数法确定的权重进行组合,称为 mEN - mCV。作为对比,利用归一化组合赋权法将原始熵值法和变异系数法确定的权重进行组合,称为 EN - CV。此外,改进的熵值法只考虑了基分类器训练精度的离散程度,没有考虑基分类器自身的分类精度。因此,本文利用归一化组合赋权法将改进的熵值法确定的权重与基分类器训练的总体精度相结合,称为 mEN - OA。

2.3 集成学习策略

利用样本数据对基分类器进行训练,利用基分类器的训练精度结合赋权方法确定基分类器的权重。利用训练后的基分类器对待识别样本进行分类,将 5 个基分类器对每个待识别样本对应于每种类别的概率输出和基分类器的权重进行融合,从而计算每个待识别样本对应于每种作物类型的概率

$$P_c=\frac{1}{n}\sum_{j=1}^{n}w_jp_{cj} \tag{8}$$

式中 P_c——待识别样本属于第 c 类作物融合概率

p_{cj}——待识别样本被第 j 个基分类器识别为第 c 类作物的概率

根据每类的融合概率,待识别样本最终被判定为最高融合概率对应的作物类型。

2.4 精度评价和对比方法

2.4.1 精度评价

参考 CDL 数据从置信度高于 90% 的区域随机生成 10 组测试样本对提出的集成学习算法进行精度评价,每组样本包含每种类别各 1 000 个样本并且独立于训练样本。结合测试样本计算混淆矩阵对作物分类结果的精度进行评价,以总体精度(Overall accuracy,OA)、用户精度(User's accuracy,UA)、生产者精度(Producer's accuracy,PA)和 F1 值作为评价指标。F1 值是 UA 和 PA 的调和平均值,能够反映分类器对目标类别的判别能力[27]。

2.4.2 精度对比

为了进一步评估所提出的集成学习算法在作物

分类中的潜力，分别利用 2 种无权集成学习算法（众数投票和概率融合）以及 4 种精度加权集成学习算法（OA 加权、F1 值加权、PA 加权和 UA 加权）进行分类，并和本文所提出的集成学习算法的精度进行比较。概率融合将待识别样本划分为融合概率最高的类别，即式（8）中 $w_j = 1$ 的情况。OA 加权、F1 值加权、PA 加权和 UA 加权算法的计算方式与式（8）类似，w_j 表示第 j 个基分类器的训练精度，分别为 OA、F1 值、PA 和 UA。

McNemar 卡方检验是一种基于二元混淆矩阵的非参数检验方法[28]，本文利用该方法检验提出的集成学习算法与 5 个基分类器、上述 2 种无权集成学习算法以及 4 种精度加权集成学习算法之间是否存在显著性差异。其计算式为

$$\chi^2 = \frac{(f_{12} - f_{21})^2}{f_{12} + f_{21}} \tag{9}$$

式中　f_{12}——被方法 1 正确分类而被方法 2 错误分类的样本数量

f_{21}——被方法 2 正确分类而被方法 1 错误分类的样本数量

当 χ^2 大于 3.84 时，表示 2 种方法分类结果具有显著性差异（$p < 0.05$）。

3　结果与分析

3.1　基分类器的训练精度评价

通过重复交叉验证对 5 个基分类器的训练精度进行评价，以研究区 A 为例（图 4）。总体来看，KNN、SVM、RF、BPNN 和 CNN 的训练精度均较高，多次实验的总体精度均值均高于 80%。其中，利用 RF 分类器获得的总体精度最高，其次是 CNN、SVM 和 BPNN，利用 KNN 分类器获得的精度最低。此外，不同分类器对于不同作物类型的分类精度也不尽相同。例如，虽然在大多数情况下，利用 RF 分类器获得的分类精度最优，但是利用 CNN 识别的花生的 F1 值最高。在 5 种作物类型中，花生和玉米的 F1 值较高，其次是棉花、水稻和大豆。

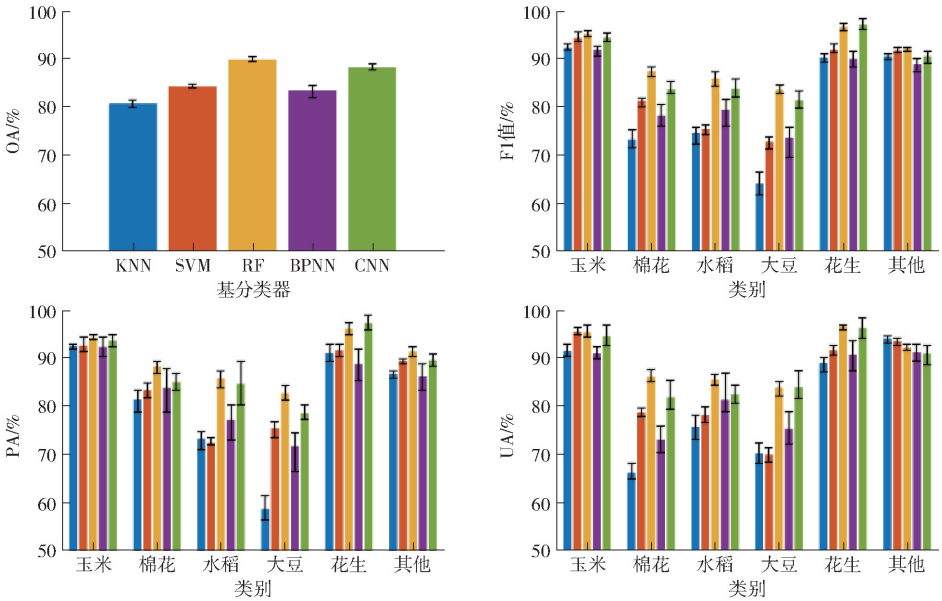

图 4　基分类器训练精度

Fig. 4　Training performance of base classifiers

3.2　不同赋权方法对比

为了评估改进的客观赋权方法在集成学习中的有效性，以 F1 值作为基分类器权重确定的指标为例，对改进的赋权方法（mEN、mCV、mEN－mCV、mEN－OA）和原始赋权方法（EN、CV、EN－CV）分配给 5 个基分类器权重值进行对比分析（图 5）。结果表明，利用改进的赋权方法和原始赋权方法确定的不同基分类器的权重存在差异。在 5 个基分类器中，训练精度最高的 RF 分类器被 mEN、mCV、mEN－mCV 和mEN－OA 方法赋予最高的权重，然而，被 EN、CV 和 EN－CV 方法赋予最低的权重。与 mEN 和 mCV 方法相比，mEN－mCV 方法进一步放大了 5 个基分类器权重的差异。此外，利用 mEN－OA 方法确定的权重与 mCV 方法确定的权重较接近，两者都考虑了基分类器的分类精度以及精度的稳定性。

利用改进赋权方法和原始赋权方法对 5 个基分类器的类别概率输出进行加权集成，并对分类精度进行比较。如图 6 所示，基于 mEN、mCV、mEN－mCV 和 mEN－OA 的集成学习算法的总体精度均值均高于基于 EN、CV 和 EN－CV 的集成学习算法的总体精度均值，表明了本文提出的改进的赋权方法在多分类器集成学习中的优势。

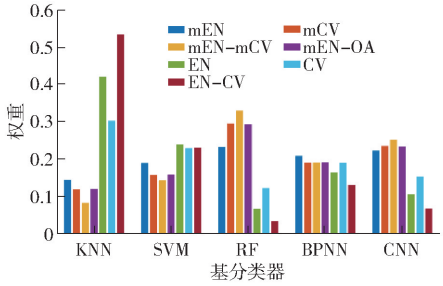

图 5 利用改进的和原始的赋权方法确定的基分类器权重

Fig. 5 Weight values of base classifiers assigned by modified and original weighting methods

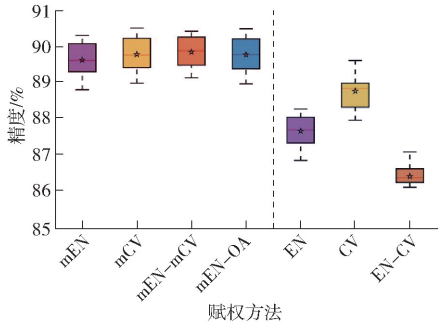

图 6 利用改进的和原始的赋权方法集成多分类器分类总体精度

Fig. 6 Classification overall accuracy of ensemble learning methods achieved by modified and original weighting methods

3.3 集成学习算法的精度评价

为了评价利用不同赋权方法和不同精度指标计算的基分类器权重对集成学习分类精度的影响，分别利用 4 个精度指标（OA、F1 值、PA 和 UA）作为 mEN、mCV、mEN－mCV 和 mEN－OA 赋权方法的输入数据，用于确定 5 个基分类器权重进而进行集成学习。利用 10 组测试样本对基于不同权重的集成学习算法的分类精度进行评价。如图 7 所示，当利用不同的精度指标作为输入数据确定基分类器的权重时，利用 4 种赋权方法获得的精度的相对顺序类似。其中，基于 mEN－mCV 的集成学习算法的分类精度略高于基于 mCV 和基于 mEN 的集成学习算法的精度，表明归一化组合赋权法比单一赋权法在多分类器集成学习中更具有优势。基于 mEN－OA 和 mCV 的集成学习算法的分类精度较接近，均高于基于 mEN 的集成学习算法。究其原因，可能是 mEN 方法只考虑了基分类器精度的稳定性，没有考虑基分类器自身的精度大小。分别以 OA、F1 值、PA 和 UA 作为 mEN－mCV 赋权方法的输入数据，构建的集成学习算法的总体精度均值较接近，简称为基于 mEN－mCV－O、mEN－mCV－F、mEN－mCV－P 和 mEN－mCV－U 的集成学习算法。其中，基于 mEN－mCV－F 的集成学习算法的总体精度的中位数高于基于 mEN－mCV－O 的集成学习算法。究其原因，可能是利用 F1 值作为输入数据计算每个基分类器的权重时，综合考虑了不同作物类别的生产者精度和用户精度。

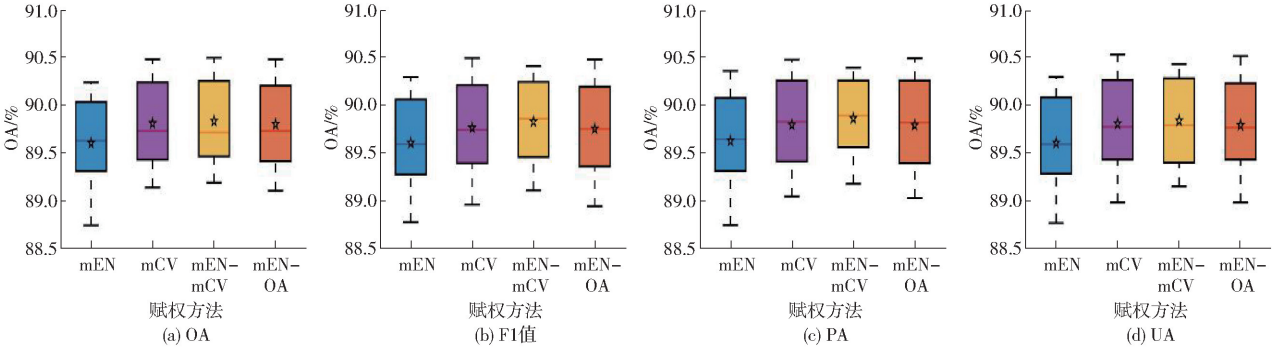

图 7 基于不同精度指标和改进的赋权方法进行集成学习的分类总体精度

Fig. 7 Classification overall accuracy achieved by ensemble learning algorithm based on modified weighting methods with four groups of indicators as input

3.4 作物分类结果及精度评价

利用基于 mEN－mCV－F 的集成学习算法对 4 个研究区进行作物分类（图 8），总体精度分别为 88.93%、93.18%、93.05% 和 93.15%。与 5 个基分类器相比，该方法在 4 个研究区的总体精度分别提高 1.12 ~ 6.45、0.75 ~ 3.98、0.45 ~ 2.70、1.15 ~ 2.50 个百分点。

以研究区 C 为例，对利用 5 个基分类器和基于 mEN－mCV－F 的集成学习算法获得的制图结果与 CDL 数据进行对比。为了避免 CDL 数据误差的影响，仅对 CDL 数据中置信度高于 90% 的像素进行分析，将置信度低于 90% 的像素划分为其他类别。如图 9 所示，红色和绿色区域分别表示被每个方法（SV）和 CDL 数据都识别为棉花和非棉花作物的区域。总体来看，利用不同方法提取的棉花种植区的空间分布基本一致。橘黄色和蓝色区域分别表示棉花被错分和漏分的区域，可以看出，利用 BPNN 方法在该区域制图的漏分误差较高，利用 KNN 和 CNN 方法在该区域制图的错分误差较高，利用基于 mEN－mCV－F 的集成学习算法在该区域制图的错分误差

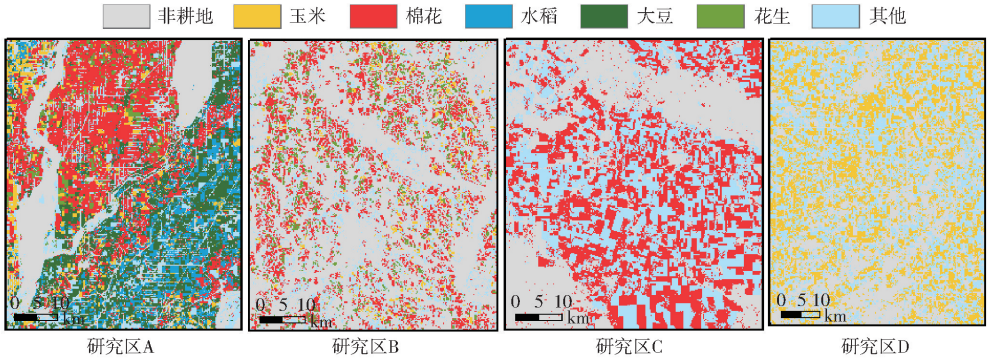

图 8　基于 mEN－mCV－F 的集成学习算法的作物分类图

Fig. 8　Crop classification maps achieved by mEN－mCV－F-based ensemble learning method

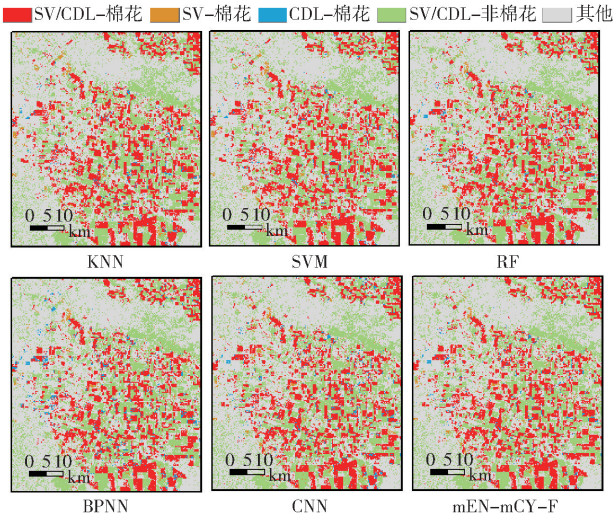

图 9　利用不同方法提取的研究区 C 棉花分布与 CDL 数据的一致性

Fig. 9　Consistency map between cotton distribution maps detected by different methods and CDL map in study area C

和漏分误差整体低于其他方法。

4　讨论

4.1　不同方法对比

为了进一步评估本文提出的集成学习算法在作物分类中的潜力，以研究区 A 为例，将本文提出的集成学习算法与 5 个基分类器（KNN、SVM、RF、BPNN 和 CNN）、2 种无权集成学习算法（众数投票和概率融合）以及 4 种精度加权集成学习算法（OA 加权、F1 值加权、PA 加权和 UA 加权）的精度进行比较（图 10）。在 5 个基分类器中，利用 RF 分类器获得的分类总体精度最高，其次为 CNN、SVM、BPNN 和 KNN。除了众数投票，利用所有集成学习算法获得的分类精度均优于利用基分类器获得的分类精度，利用概率融合和 4 种精度加权方法获得的分类精度优于利用众数投票和 5 个基分类器获得的精度。就总体精度均值而言，基于 mEN－mCV－O、mEN－mCV－F、mEN－mCV－P 和 mEN－mCV－U

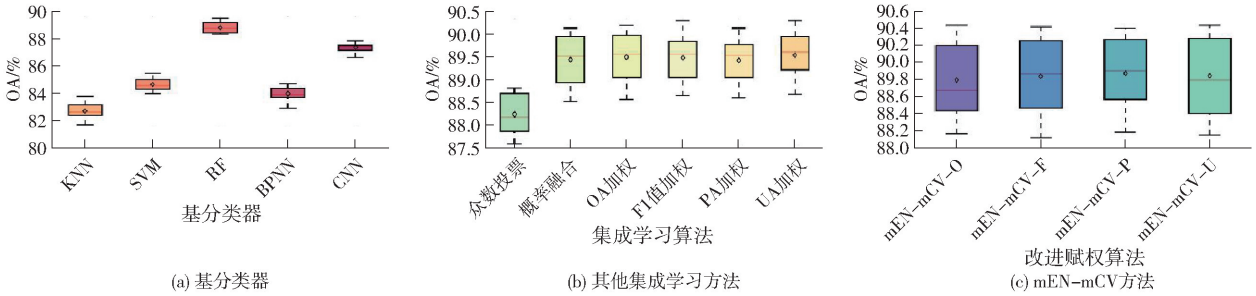

(a) 基分类器　　(b) 其他集成学习方法　　(c) mEN-mCV方法

图 10　不同算法分类总体精度对比

Fig. 10　Comparison of classification overall accuracy achieved by different algorithms

的集成学习算法的精度较为接近，且均优于其他方法。此外，在多次重复实验中，基于 mEN－mCV－F 的集成学习算法的总体精度中位数高于基于 mEN－mCV－O 的集成学习算法。

利用 McNemar 检验进一步评估利用不同算法获得的分类结果之间的统计差异，并重复该实验 10 次。如图 11 所示，数字表示 10 次重复实验中显著性水平为 95%（$p<0.05$）的次数，在大多数情况下，集成学习算法与基分类器之间的差异具有统计学意义。值得注意的是，在 10 次重复实验中，超过 5 次实验利用随机森林与 2 种无权集成学习算法和 4 种精度加权集成学习算法获得的分类结果没有统计学差异，其原因可能是随机森林本身就是一种集成学习算法，能够通过构建多棵决策树进行投票从而获得最终分类结果，因此具有较高的分类精度。利用众数投票法获得的分类结果与利用其他集成学习算

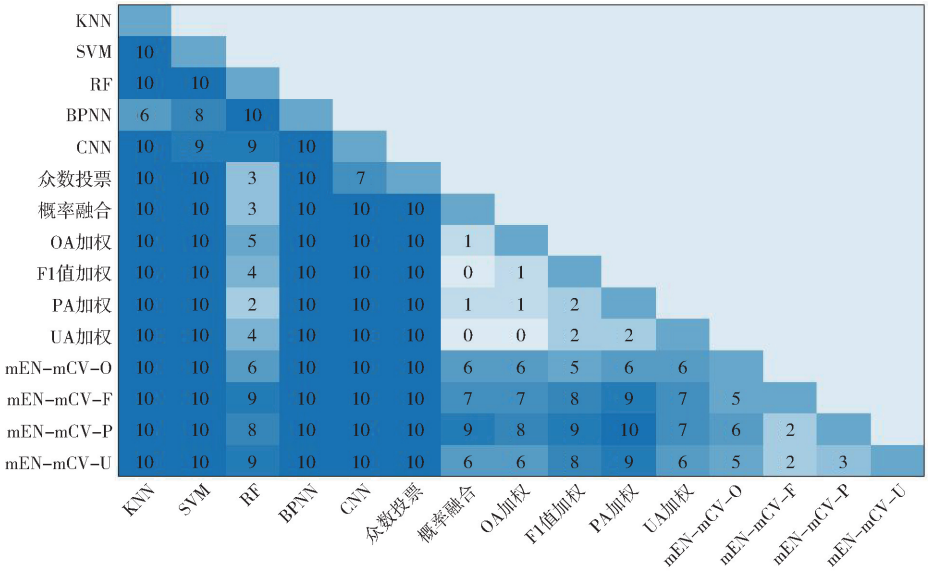

图 11 基分类器与不同集成学习算法之间的 McNemar 检验结果

Fig. 11 Statistical significance between pairs of five base classifiers and ensemble learning methods using McNemar test

法获得的分类结果具有统计学差异。在大多数情况下,本文提出的集成学习算法,特别是基于 mEN – mCV – P 和 mEN – mCV – F 的算法与其他算法之间具有统计学差异。这些结果表明了提出的集成学习算法在作物分类中的有效性和潜力。此外,在 10 次重复实验中,基于 mEN – mCV – P、mEN – mCV – F、mEN – mCV – U 的算法和基于 mEN – mCV – O 的算法有 5 次以上存在统计学差异,表明了相比于总体精度,利用具体类别的精度确定基分类器的权重更具优势。

4.2 方法优势分析

与无权集成学习和精度加权集成学习算法相比,本文提出的集成学习算法的特色在于基分类器的权重确定,它既考虑了基分类器的训练精度,又考虑了基分类器在多次重复实验中的稳定性。mCV 方法的表现优于 mEN 方法,因为前者既考虑了基分类器的训练精度又考虑了稳定性,而后者只考虑了基分类器精度的稳定性。与 mEN 和 mCV 方法相比,mEN – mCV 方法进一步放大了 5 个基分类器权重的差异,获得的分类精度略高于 2 个单一赋权方法。以 F1 值作为 mEN – mCV 方法的输入,在确定不同分类器的权重时兼顾了不同类别的生产者精度和用户精度,因此,其表现优于利用总体精度作为 mEN – mCV 方法的输入。

由于本文侧重于方法研究,在特征方面仅利用了时序 NDVI 作为区分不同作物的输入特征。为了进一步测试算法稳定性,以研究区 A 为例,分别以 GNDVI、$NDVI_{RE1}$、LSWI 及与 VV 极化后向散射系数的组合(NDVI + VV、GNDVI + VV、$NDVI_{RE1}$ + VV、LSWI + VV)作为输入特征,对基分类器和基于 mEN – mCV – F 的集成学习算法的分类总体精度进行比较。如图 12 所示,利用不同特征进行作物分类时,不同基分类器的精度表现存在差异,而利用基于 mEN – mCV – F 的集成学习算法获得的总体精度均值均优于 5 个基分类器的精度,进一步表明了本文提出算法的有效性。

此外,本文通过重复交叉验证对基分类器的训练精度进行评价,进而结合赋权方法确定基分类器的客观权重,该过程不需要人为干预,在不同分类情景下对于每个分类器分配的权重不同,可以看作是一个自适应计算权重的过程。将基于 mEN – mCV – F 的集成学习算法应用于 4 个具有不同数量不同目标作物的研究区时均取得了较好的效果,表明所提出的算法在多作物分类和单一作物类型识别中均具有较好的鲁棒性。

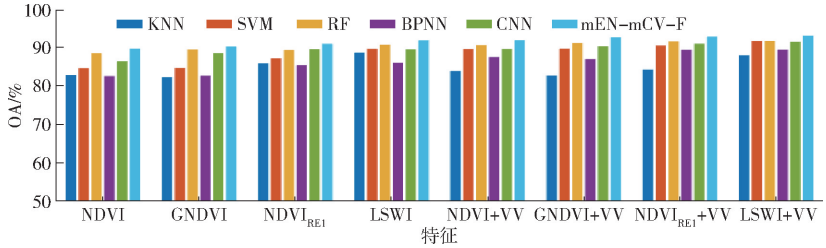

图 12 基于不同输入特征的分类总体精度

Fig. 12 Classification overall accuracy achieved by different input features

4.3　不确定性和潜在改进

虽然本文提出的集成学习算法具有上述优势，但仍存在一些不确定性和局限性，需要在未来的研究中进一步完善。集成学习算法的精度在一定程度上取决于基分类器的表现，在多次重复实验过程中，本文提出的集成学习算法在不同场景（不同区域、不同作物类别、不同训练样本）获得的表现均优于 5 个基分类器，其中，相比于随机森林提升的空间相对较小。以往的研究也有类似的发现，LEI 等[29]提出的基于多分类器集成的面向对象迭代分类方法比随机森林、支持向量机、决策树、贝叶斯和 K 最近邻法 5 个基分类器的精度提高 0.96 ~ 3.65 个百分点。WANG 等[30]提出的基于加权投票法的城市区域变化检测方法比 K 最近邻法、支持向量机、极度学习机和随机森林方法 4 个基分类器的总体精度提高 0.35 ~ 5.22 个百分点，其中，比随机森林提高 0.42 个百分点。原因可能是随机森林本身是一种集成学习算法，其精度较高，以其作为基分类器进行集成学习的总体精度提升空间相对较小。在未来的研究中，可以对不同的基分类器数量及组合方式对集成学习算法的分类精度的影响进行评估。

此外，本文提出的算法属于监督分类方法，监督分类器的分类精度在一定程度上依赖于训练样本的数量和质量，该方法难以应用于样本数据缺乏的区域。如何在集成学习的过程中充分挖掘并利用被基分类器正确分类的样本是今后研究的一个潜在改进方向。

5　结论

（1）本文对熵值法和变异系数法这两种客观赋权方法进行改进，提出了改进的熵值法和改进的变异系数法，对 5 个基分类器进行加权集成。结果表明，与原始赋权方法相比，利用改进的赋权方法分配给每个基分类器的权重更为合理，获得的分类精度高于利用原始赋权方法获得的分类精度。

（2）利用归一化组合赋权法对改进的熵值法和改进的变异系数法进行组合获得的分类精度略高于基于单一赋权方法获得的分类精度。其中，基于 mEN - mCV - F 的集成学习算法兼顾了不同类别的生产者精度和用户精度，总体表现优于基于 mEN - mCV - O 的集成学习算法。

（3）与基分类器相比，基于 mEN - mCV - F 的集成学习算法在 4 个研究区分类总体精度分别提高 1.12 ~ 6.45、0.75 ~ 3.98、0.45 ~ 2.70、1.15 ~ 2.50 个百分点。与传统的众数投票、概率融合及精度加权方法相比，本文提出的集成学习算法同时考虑了基分类器的精度和稳定性，在作物分类中具有一定的潜力。

参　考　文　献

[1] 赵龙才，李粉玲，常庆瑞. 农作物遥感识别与单产估算研究综述[J]. 农业机械学报，2023，54(2)：1 - 19.
ZHAO Longcai，LI Fenling，CHANG Qingrui. Review on crop type identification and yield forecasting using remote sensing [J]. Transactions of the Chinese Society for Agricultural Machinery，2023，54(2)：1 - 19. (in Chinese)

[2] 杨颖频，吴志峰，骆剑承，等. 时空协同的地块尺度作物分布遥感提取[J]. 农业工程学报，2021，37(7)：166 - 174.
YANG Yingpin，WU Zhifeng，LUO Jiancheng，et al. Parcel-based crop distribution extraction using the spatiotemporal collaboration of remote sensing data[J]. Transactions of the CSAE，2021，37(7)：166 - 174. (in Chinese)

[3] 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.
XIE Yi，ZHANG Yongqing，XUN Lan，et al. Crop classification based on multi-source remote sensing data fusion and LSTM algorithm[J]. Transactions of the CSAE，2019，35(15)：129 - 137. (in Chinese)

[4] 周俊伟，冯浩，董勤各. 基于不同时间尺度与特征优选的黄淮海平原冬小麦识别[J]. 农业机械学报，2024，55(9)：262 - 274.
ZHOU Junwei，FENG Hao，DONG Qin'ge. Identification of winter wheat in Huang - Huai - Hai Plain based on different time scales and feature preference[J]. Transactions of the Chinese Society for Agricultural Machinery，2024，55(9)：262 - 274. (in Chinese)

[5] 解毅，王佳楠，刘钰. 基于 Sentinel - 1/2 数据特征优选的冬小麦种植区识别方法研究[J]. 农业机械学报，2024，55(2)：231 - 241.
XIE Yi，WANG Jia'nan，LIU Yu. Research on winter wheat planting area identification method based on Sentinel - 1/2 data feature optimization[J]. Transactions of the Chinese Society for Agricultural Machinery，2024，55(2)：231 - 241. (in Chinese)

[6] 郭交，王鹤颖，项诗雨，等. 基于多特征优化的 PolSAR 数据农作物精细分类方法[J]. 农业机械学报，2024，55(9)：275 - 284.
GUO Jiao，WANG Heying，XIANG Shiyu，et al. Crop classification based on PolSAR data using multiple feature optimization [J]. Transactions of the Chinese Society for Agricultural Machinery，2024，55(9)：275 - 284. (in Chinese)

[7] 冯权泷，任燕，姚晓闯，等. 基于多源光学雷达数据融合的黄淮海平原冬小麦识别[J]. 农业机械学报，2023，54(2)：160 - 168.
FENG Quanlong，REN Yan，YAO Xiaochuang，et al. Identification of winter wheat in Huang - Huai - Hai Plain based on multi-source optical radar data fusion[J]. Transactions of the Chinese Society for Agricultural Machinery，2023，54(2)：160 - 168.

(in Chinese)
[8] BULLOCK E L, WOODCOCK C E, HOLDEN C E. Improved change monitoring using an ensemble of time series algorithms [J]. Remote Sensing of Environment, 2020, 238: 111165.
[9] CHEN Bin, TU Ying, SONG Yimeng, et al. Mapping essential urban land use categories with open big data: results for five metropolitan areas in the United States of America[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2021, 178: 203 - 218.
[10] ZHANG Caiyun. Applying data fusion techniques for benthic habitat mapping and monitoring in a coral reef ecosystem[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2015, 104: 213 - 223.
[11] SCHULZ D, YIN H, TISCHBEIN B, et al. Land use mapping using Sentinel - 1 and Sentinel - 2 time series in a heterogeneous landscape in Niger, Sahel[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2021, 178: 97 - 111.
[12] SHEN Huaifei, LIN Yinghao, TIAN Qingjiu, et al. A comparison of multiple classifier combinations using different voting-weights for remote sensing image classification[J]. International Journal of Remote Sensing, 2018, 38(11): 3705 - 3722.
[13] SAHOO M, SAHOO S, DHAR A, et al. Effectiveness evaluation of objective and subjective weighting methods for aquifer vulnerability assessment in urban context[J]. Journal of Hydrology, 2016, 541: 1303 - 1315.
[14] 雷文韬, 古杰, 谢宏坤. 基于"三生"空间的湖南省土地利用格局及多功能演变[J]. 农业工程学报, 2024, 40(17): 283 - 293.
LEI Wentao, GU Jie, XIE Hongkun. Land use pattern and multifunctional evolution in Hunan Province using "production-living-ecosystem" space[J]. Transactions of the CSAE, 2024, 40(17): 283 - 293. (in Chinese)
[15] WANG Zihan, HUANG Fubin, LIU Jing, et al. Does solar PV bring a sustainable future to the poor? —an empirical study of anti-poverty policy effects on environmental sustainability in rural China[J]. Energy Policy, 2020, 145: 111723.
[16] 徐云飞, 程琦, 魏祥平, 等. 变异系数法结合优化神经网络的无人机冬小麦长势监测[J]. 农业工程学报, 2021, 37(20): 71 - 80.
XU Yunfei, CHENG Qi, WEI Xiangping, et al. Monitoring of winter wheat growth under UAV using variation coefficient method and optimized neural network[J]. Transactions of the CSAE, 2021, 37(20): 71 - 80. (in Chinese)
[17] XUN Lan, ZHANG Jiahua, CAO Dan, et al. A novel cotton mapping index combining Sentinel - 1 SAR and Sentinel - 2 multispectral imagery[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2021, 181: 148 - 166.
[18] 田欣媛, 张永红, 刘睿, 等. 考虑植被红边信息的多时相 Sentinel - 2 大范围冬小麦提取研究[J]. 遥感学报, 2022, 26(10): 1988 - 2000.
TIAN Xinyuan, ZHANG Yonghong, LIU Rui, et al. Winter wheat planting area extraction over wide area using vegetation red edge information of multi-temporal Sentinel - 2 images[J]. National Remote Sensing Bulletin, 2022, 26(10): 1988 - 2000. (in Chinese)
[19] ZHONG Liheng, HU Lina, ZHOU Hang. Deep learning based multi-temporal crop classification[J]. Remote Sensing of Environment, 2019, 221: 430 - 443.
[20] CHEN Zhulin, JIA Kun, XIAO Chenchao, et al. Leaf area index estimation algorithm for GF - 5 hyperspectral data based on different feature selection and machine learning methods[J]. Remote Sensing, 2020, 12: 2110.
[21] ZHANG Hongyan, KANG Jinzhong, XU Xiong, et al. Accessing the temporal and spectral features in crop type mapping using multi-temporal Sentinel - 2 imagery: a case study of Yi'an County, Heilongjiang province, China[J]. Computers and Electronics in Agriculture, 2020, 176: 105618.
[22] BREIMAN L E O. Random forests[J]. Machine Learning, 2001, 45: 5 - 32.
[23] 王丽美, 靳国旺, 熊新, 等. 耕地细碎化农业区冬小麦遥感制图方法[J]. 农业工程学报, 2022, 38(22): 190 - 198.
WANG Limei, JIN Guowang, XIONG Xin, et al. Winter wheat mapping in land fragmentation areas using remote sensing data [J]. Transactions of the CSAE, 2022, 38(22): 190 - 198. (in Chinese)
[24] LIAO Juan, ZAND Ying, LUO Xiwen, et al. The relations of leaf area index with the spray quality and efficacy of cotton defoliant spraying using unmanned aerial systems (UASs)[J]. Computers and Electronics in Agriculture, 2020, 169: 105228.
[25] LI W, HUGHES M. Coastal wetland mapping using ensemble learning algorithms: a comparative study of bagging, boosting and stacking techniques[J]. Remote Sensing, 2020, 12: 1683.
[26] 马爽, 张卓然, 张钧泳, 等. 理化复合参数和神经网络结合的冬小麦长势遥感监测[J]. 农业工程学报, 2024, 40(14): 91 - 99.
MA Shuang, ZHANG Zhuoran, ZHANG Junyong, et al. Remote sensing monitoring of winter wheat growth using physico-chemical composite parameter and neural network[J]. Transactions of the CSAE, 2024, 40(14): 91 - 99. (in Chinese)
[27] GUO Xiaoye, LI Peijun. Mapping plastic materials in an urban area: development of the normalized difference plastic index using WorldView - 3 superspectral data[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2020, 169: 214 - 226.
[28] SONOBE R, YAMAYA Y, TANI H, et al. Assessing the suitability of data from Sentinel - 1A and 2A for crop classification [J]. GIScience and Remote Sensing, 2017, 54(6): 918 - 938.
[29] LEI Guangbin, LI Ainong, BIAN Jinhu, et al. OIC - MCE: a practical land cover mapping approach for limited samples based on multiple classifier ensemble and iterative classification[J]. Remote Sensing, 2020, 12: 987.
[30] WANG Xin, LIU Sicong, DU Peijun, et al. Object-based change detection in urban areas from high spatial resolution images based on multiple features and ensemble learning[J]. Remote Sensing, 2018, 10: 276.