doi:10.6041/j.issn.1000-1298.2025.11.040

基于集成和置信学习的半监督作物遥感分类方法

车红岩[1,2]　潘耀忠[1,3]　夏兴生[1,4]　王林刚[1,4]　黄永生[1,4]　陈　琼[1,4]

(1. 青海师范大学高原科学与可持续发展研究院, 西宁 810016; 2. 兰州财经大学农林经济管理学院, 兰州 730020;
3. 北京师范大学地理科学学部遥感科学国家重点实验室, 北京 100875; 4. 青海师范大学地理科学学院, 西宁 810016)

摘要: 作物分布制图是现代农业管理的关键,可为作物产量预测和精准农业决策提供科学依据。尽管深度学习在作物分类中展现出巨大潜力,但其实际应用仍受限于样本获取成本和分类精度。本研究提出了一种基于集成学习和置信学习的半监督分类框架(Ensemble and confident learning based semi-supervised classification framework, ECL-SSCF),旨在利用有限的地面标记样本实现高精度的作物分类。ECL-SSCF 框架包含集成学习和置信学习 2 个模块。集成学习模块通过并行训练多个深度学习模型,并采用相对众数投票法整合多个深度学习模型的分类结果,从而提升分类精度。而置信学习模块则基于模型的预测概率评估伪标签的置信度,筛选出高置信度的伪样本以扩充训练集,克服小样本导致的过拟合现象。在湖北省枝江市和山东省桓台县 2 个研究区的作物分类结果显示:ECL-SSCF 通过引入置信学习策略,在 2 个研究区的伪样本的总体精度分别提升 17.2、9.3 个百分点,超越单一深度学习模型(如 LSTM、Conv1D、ConvLSTM 和 TempCNN),利用提纯的伪样本训练 4 种深度学习模型并集成得到 ECL-SSCF 的分类结果,ECL-SSCF 在 2 个研究区的总体分类精度分别达到了 90.4% 和 86.3%,明显优于任何单一深度学习模型。为了更全面地评估 ECL-SSCF 的性能,进一步探讨了其生成的伪样本数量和质量对 5 种模型预测性能的影响。实验结果表明,当样本数量达到标准样本集 30% 左右,噪声样本比例低于标准样本集 30% 时,ECL-SSCF 均表现出稳健的性能。说明集成学习和置信学习策略的结合使 ECL-SSCF 获得了高质量的样本和稳定的分类性能,缓解了深度学习模型对大量人工标记样本的依赖,为进行大尺度的作物遥感分类制图提供了新的技术方案。

关键词: 遥感; 作物分类; 置信学习; 半监督学习; 集成学习

中图分类号: S29; TP79　　**文献标识码**: A　　**文章编号**: 1000-1298(2025)11-0418-15　　**OSID**:

Semi-supervised Crop Remote Sensing Classification Based on Ensemble and Confident Learning

CHE Hongyan[1,2]　PAN Yaozhong[1,3]　XIA Xingsheng[1,4]　WANG Lin'gang[1,4]
HUANG Yongsheng[1,4]　CHEN Qiong[1,4]

(1. *Academy of Plateau Science and Sustainability*, *Qinghai Normal University*, *Xining* 810016, *China*
2. *School of Agriculture and Forestry Economics and Management*, *Lanzhou University of Finance and Economics*, *Lanzhou* 730020, *China*
3. *State Key Laboratory of Remote Sensing Science*, *Beijing Normal University*, *Beijing* 100875, *China*
4. *School of Geographical Sciences*, *Qinghai Normal University*, *Xining* 810016, *China*)

Abstract: Crop distribution mapping is pivotal in modern agricultural management, providing a scientific basis for crop yield prediction and precision agriculture decision-making. Despite its significant potential in crop classification, the practical application of deep learning is still limited by the cost of sample acquisition and classification accuracy. An ensemble learning and confident learning based semi-supervised classification framework (ECL-SSCF) was proposed, which aimed to achieve high-precision crop mapping with a small number of ground-truth samples. The ECL-SSCF consisted of two modules: ensemble learning and confident learning. The ensemble learning module improved classification accuracy by training multiple deep learning models in parallel and integrating their classification results through a plurality voting method. The confident learning module evaluated the confidence of pseudo-samples based on the model's predictive probabilities and selected high-confidence pseudo-samples to expand the training

收稿日期: 2024-07-29　修回日期: 2024-09-24

基金项目: 国家重点研发计划项目(2023YFB3906201)和国家自然科学基金项目(42201027)

作者简介: 车红岩(1981—),女,博士生,兰州财经大学讲师,主要从事农业遥感研究,E-mail: chehy@lzufe.edu.cn

通信作者: 夏兴生(1989—),男,副教授,博士生导师,主要从事地理信息和遥感技术研究,E-mail: xxs@qhnu.edu.cn

set, thus overcoming overfitting caused by small sample sizes. Crop classification results in the two study areas, Zhijiang city and Huantai county in China, showed that by introducing the confident learning strategy, the overall accuracy of pseudo-samples in both study areas was improved by 17.2 percentage points and 9.3 percentage points, respectively, surpassing single deep learning models such as LSTM, Conv1D, ConvLSTM, and TempCNN. By training four deep learning models with purified pseudo-samples and integrating their results, ECL－SSCF achieved an overall classification accuracy of 90.4% and 86.3% in the two study areas, significantly outperforming any single deep learning model. To more comprehensively evaluate the performance of ECL－SSCF, the impact of the quantity and quality of its generated pseudo-samples on the predictive performance of five models were further explored. The experimental results indicated that ECL－SSCF demonstrated robust performance when the sample size reached approximately 30% of the standard sample set and the proportion of noisy samples was below 30% of the standard sample set. This suggested that the combination of ensemble learning and confident learning strategies endowed ECL－SSCF with high-quality samples and stable classification performance, alleviating the dependence of deep learning models on a large number of manually labeled samples and providing a reference scheme for large-scale remote sensing crop mapping.

Key words: remote sensing; crop classification; confident learning; semi supervised learning; ensemble learning

0　引言

准确获取作物的空间分布信息在作物产量预估、农业生产管理与农业保险等方面具有重要的科学与实践意义。随着高分辨率遥感卫星观测能力不断增强，利用遥感数据结合机器学习算法成为主流的作物制图范式[1]。在诸多作物机器学习分类算法中，深度学习方法因其更深以及更复杂的结构，可以自动地学习隐藏层内部的代表性和判别性特征进而实现更好的作物识别[2]，被认为是一项突破性技术并越来越多的应用到作物识别领域[3-4]。然而，深度学习方法本质上还是遵循“特征-样本-分类器”的模式[1]，因此，样本的数量和质量、分类器的稳定性仍是分类精度的制约因素。特别是高质量的大量样本标注需要投入巨大的人力、物力和时间成本，导致样本的获取速度落后于实际的作物遥感识别需求，阻碍了作物分布遥感提取的时效性。因此，利用有限的样本，研发基于扩充样本的稳定深度学习作物分类模型具有重要的应用价值。

半监督学习作为监督学习和无监督学习[5]的混合学习，基于相同类别的标记样本和无标记样本在特征空间上更为接近的假设，可利用有限的标记数据进行模型迭代训练从而达到扩充样本的目的[6-7]。现阶段，半监督学习扩充样本的方法主要包括生成对抗网络(Generative adversarial network, GAN)[8-11]和基于图的标签传播算法[12-13]。虽然两种方法结合不同的机器学习模型均有效扩充了样本量，并取得了良好的分类效果，但是，无论是基于图的标签传播算法，还是生成对抗网络的方法，在扩充标记样本的过程中仍然会产生错误的标注样本导致误差传播，影响最终的分类结果。针对该问题，有研究引入置信学习方法[13-14]通过表征和识别样本集中的错误样本并对其进行清除来提升样本质量，为后续基于半监督学习应用中的样本数量扩充及样本质量提升提供了思路。

深度学习模型在作物识别中的成功很大程度上取决于其稳定的分类性能。但是，这些模型通常需要大量的标注样本来驱动训练，特别是当网络结构变得更深、参数数量增多时，对样本的需求也随之增加。当标注样本数量过少时，深度学习算法容易发生过拟合，即模型在训练数据集上表现优异，但在测试集上性能下降[15]。针对小样本作物分类任务，现有研究主要采用几种相互独立的方法，通过比较它们的分类结果以确定最佳方法[3,16-17]。然而，由于遥感影像受到成像时间、光照条件、作物品种、地形、土壤条件、气候条件和耕作方式等多种因素影响，还没有适用于所有遥感作物分类任务的通用深度学习模型。这意味着单一深度学习模型可能会在某些特定作物类型上表现出色，但在其他类型上则效果欠佳，这会导致分类精度不足。因此，多分类器的结合使用成为作物分类的新方式，并且已有研究在浮游植被制图和土地覆盖分类中取得了较为满意分类效果[18-20]，为探索集成学习方法在少量样本情景下的作物识别提供了操作参考。

综上所述，置信学习方法为半监督学习实现高质量样本扩充提供了思路，集成深度学习为少量样本分类的稳定性提供了参考，二者进一步集成是否能够获得更好的结果则值得探讨。为此，针对作物的遥感快速提取，本文提出一种结合集成和置信学

习的半监督学习作物分类框架(Ensemble and confident learning based semi-supervised classification framework, ECL-SSCF)。ECL-SSCF 通过生成高质量的样本来训练集成学习模型从而提升作物分类精度,其新颖之处在于采用标签选择策略,利用置信学习标记伪标签,迭代训练集成学习模型。具体包括:首先,利用有限的标记样本和集成学习模型训练生成伪标签,并评估每个伪标签的置信度;然后,高置信度的伪标签被用来扩充样本集进行集成学习模型训练,解决由于少量样本引起的过拟合问题。最后,半监督学习框架通过交替训练集成学习和置信学习模块,逐步增加伪标签中高置信标签的比例,从而进一步提高分类精度。

1 方法设计

本研究一方面要实现少量样本的数量和质量扩充,另一方面也要提升分类模型性能的稳定性,因此,总体的方案是采用半监督分类的思想,结合集成学习和置信学习策略,实现可靠的高精度作物分类精度。主要包括半监督分类框架构建,集成学习模块和置信学习模块嵌入,并通过迭代训练集成学习和置信学习模块,实现在有限标记样本下的泛化能力提升,提高模型的分类性能。

1.1 半监督分类框架

本研究利用少量样本训练监督学习分类器,将分类结果作为伪标签,选择高置信度的伪标签作为新的训练样本集,由迭代训练不断扩大样本集的规模,取得比依靠原始少量训练样本进行监督分类更好的效果,实现半监督分类。如图 1 所示,半监督分类框架由 2 个核心模块组成:集成学习和置信学习。集成学习模块利用极少量样本并行训练多个深度学习模型,输出多个分类结果,并采用相对众数投票法(Plurality voting)将每个像素上出现频率最高的类别作为最终分类结果,从而提升模型的分类精度。置信学习模块用来清除伪标签中的噪声标签并保存纯净的标签用于模型训练。具体来说,集成学习模块的分类结果被作为伪标签,将 SVM 的分类结果作为真实标签,并把 SVM 分类器产生的预测概率作为置信度。因此,对伪标签分类别按置信度排序并剔除低置信度的伪标签,保留高置信度的伪标签作为新的训练样本集,再次输入到集成学习模块中进行迭代训练。最终,当执行过置信学习操作后的伪标签精度不再提升,说明集成学习模型已经收敛,迭代训练终止,获得最终作物分类结果。

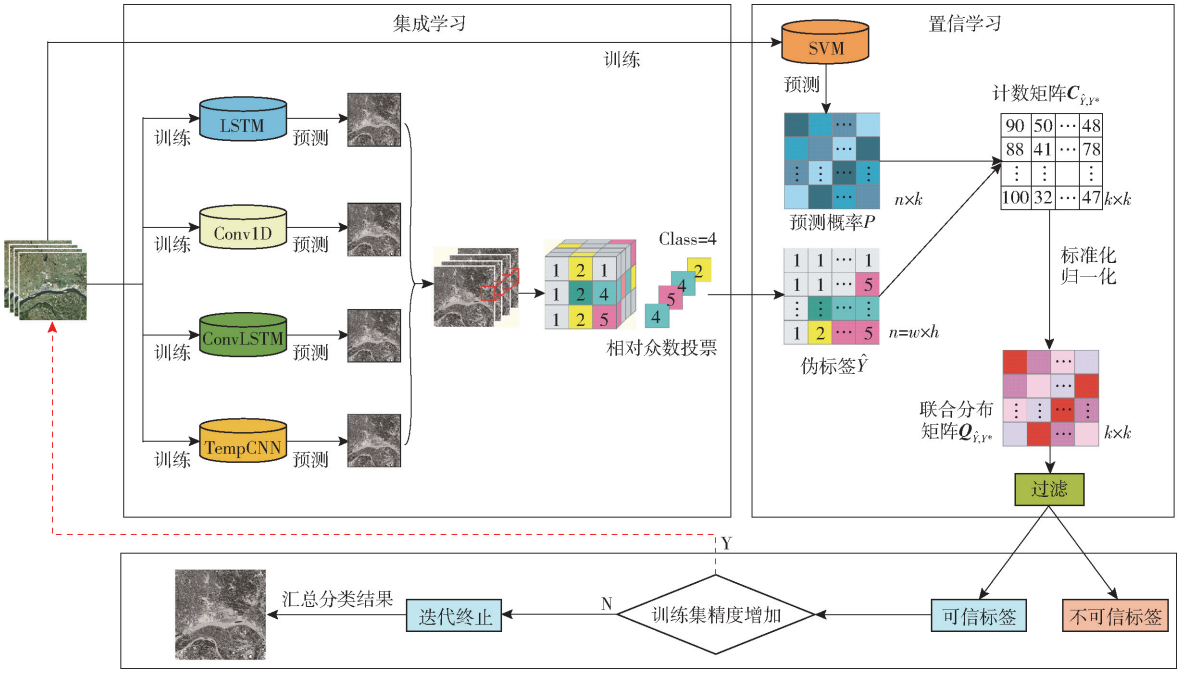

图 1 ECL-SSCF 框架

Fig. 1 Framework of ECL-SSCF

1.2 集成学习模块

集成学习模块通过集成多个深度学习模型的分类结果来完成作物分类,以提升模型的分类精度。首先,考虑到作物生长有其独特的物候表现,为了充分利用作物生长季的物候规律,选择能覆盖研究区主粮作物(如冬小麦)全生长季的影像。因此,在模型的选取上以能处理序列数据的模型为主。本研究选用了 4 种深度学习模型:长短期记忆(Long short-term memory, LSTM)、Conv1D、ConvLSTM、TempCNN(图 1)。这 4 种模型采取了不同的策略,但都能有

效处理时间长度不等的序列数据。其中，LSTM[21]更擅长捕捉时间序列数据中像素的全局特征和长期依赖关系，可以分析不同长度的作物生长周期所需要的特性；Conv1D[22]和 TempCNN[23]是包含卷积操作的模型，更侧重于提取作物地块的局部特征和空间结构；ConvLSTM[24]结合了卷积神经网络和 LSTM 的优点，不仅能够提取局部特征，还能够捕捉时间序列数据中的时间依赖性。综上，选择这 4 种模型进行集成学习，是基于它们在处理时间序列数据方面的独特优势和互补性，从而提高预测的准确性和泛化能力。

对于 4 种深度学习模型输出的整合，二分类适合用众数投票规则，由于本研究进行多种作物分类，因此，使用相对众数投票法来整合 4 种深度学习模型的输出结果，选择被大多数模型预测的类标签，所有模型的分类结果具有相同的权重。

假设对于任意像素 x_i 及其所对应的类别 y_i，m 个模型的预测结果是 $\{\hat{y}_{i1}(x_i),\hat{y}_{i2}(x_i),\cdots,\hat{y}_{im}(x_i)\}$，则 x_i 最终的类别为

$$\hat{y}_i=\mathrm{mode}\{\hat{y}_{i1}(x_i),\cdots,\hat{y}_{im}(x_i)\} \tag{1}$$

式中　mode——m 个模型预测结果 $\{\hat{y}_{i1}(x_i),\hat{y}_{i2}(x_i),\cdots,\hat{y}_{im}(x_i)\}$ 中出现频率最高的类别，如：$\mathrm{mode}\{1,2,3,3,5\}=3$

对于某个像素的类别出现多个众数的情况（没有众数属于多个众数的特殊情况），随机选择其中一个作为该像素最终的类别。$\hat{y}_i$ 将作为伪标签成为置信学习模块的一个输入。

1.3　置信学习模块

小样本学习（Few-shot learning）旨在解决在训练集中只有很少样本的情况下进行分类和推理的问题[25]。尽管使用集成学习模型提升了作物的相对分类精度，但样本的数量和质量仍是提升模型分类性能的关键，由于小样本引起的模型过拟合会产生不稳定的分类结果，如果将不稳定的分类结果作为伪标签直接进行半监督学习迭代训练会导致严重的误差传播。因此，本研究引入置信学习策略，在每一轮的迭代训练过程中按类别分层动态过滤掉不可信伪标签以提升伪标签的准确性。考虑到没有真实标签，而支持向量机（Support vector machine，SVM）能利用少量的样本作为支持向量，通过寻找超平面来完成少量样本分类任务[26-27]。因此，将 SVM 的分类结果作为真实标签，并把 SVM 分类器产生的预测概率作为置信度。该方法的基本假设是，SVM 已经学习了每类作物的关键特征，目前选取的大部分标签都应该是准确的，而且离群值的比例很小，从而可以使用一个类别的高置信度标签来表示该类别的最典型特征。因此，对集成学习得到的伪标签 $\hat{y}_i$ 利用其所对应的 SVM 得到的预测概率进行排序，并剔除 $\hat{y}_i$ 中的低置信度样本。该方法的优点是可以在没有任何成本的情况下，利用模型本身的输出来提高标签的置信度，并且随着不断训练，优化能力会稳步提高。

置信学习（Confident learning）[28]包括 2 个输入：伪标签 $\hat{Y}$ 和预测概率 P。假设数据集为 $\{X,Y\}=\{x_i,y_i\}_{i=1}^n$，$y_i$ 是任意一个像素 x_i 所对应的类别，n 是像素总数。集成模型得到的伪标签为 $\hat{Y}=\{\hat{y}_i\}_{i=1}^n$。SVM 输出的各类的预测概率为 $P=\{p[i][j]\}$（$i=1,2,\cdots,n$；$j=1,2,\cdots,k$），其中 $p[i][j]$ 表示第 i 个像素属于第 j 类的概率，k 表示类别数。由于事实上并不会获得真实标签 Y，因此采取 SVM 交叉验证对真实标签可信的估计 $Y^*=\{y_i^*\}_{i=1}^n$ 近似作为真值标签 Y。

（1）估计伪标签 $\hat{Y}$ 和真值标签 Y^* 的联合分布

伪标签 $\hat{Y}$ 和真值标签 Y^* 的联合分布提供了它们之间的关联概率分布，直观地量化了伪标签中各类错误的发生情况，在此通过以下步骤估计联合分布。

①计算类别概率阈值。利用 SVM 对数据集进行交叉验证（训练并预测），计算第 i 个样本在第 j 个类别下的概率 $p[i][j]$，计算 SVM 预测类别 j 下的平均概率 t_j，并将其作为类别 j 的置信度阈值，t_j 计算公式为

$$t_j=\frac{1}{|X_{Y^*=j}|}\sum_{\substack{1\leqslant i\leqslant n\\ y_i^*=j}}p[i][j] \tag{2}$$

式中　$|X_{Y^*=j}|$——Y^* 中标签为 j 的样本总数

②判断真实标签。对于样本 i，其真实标签 y_i^* 为 $p[i]$ 中最大向量分量的索引，即：$\mathrm{argmax}\ p[i]$，并且满足 $p[i][j]>t_j$。

③计算计数矩阵 $\boldsymbol{C}_{\hat{Y},Y^*}$。将伪标签为 $\hat{Y}$、真实标签为 Y^* 的样本统计表示为计数矩阵 $\boldsymbol{C}_{\hat{Y},Y^*}$。

$$C_{\hat{Y},Y^*}[i][j]=|\hat{X}_{\hat{Y}=i,Y^*=j}| \tag{3}$$

其中 $C_{\hat{Y},Y^*}[i][j](i=j)$ 为 $\boldsymbol{C}_{\hat{Y},Y^*}$ 的对角线元素，真实标签和伪标签均标注为类别 i 的样本总数；$C_{\hat{Y},Y^*}[i][j](i\neq j)$ 为 $\boldsymbol{C}_{\hat{Y},Y^*}$ 的非对角线元素，真实标签属于类别 j 却在伪标签中被标注为类别 i 的样本总数；$\hat{X}_{\hat{Y}=i,Y^*=j}=\{x\in X_{\hat{Y}=i}:p[i][j]>t_j,j=\mathrm{argmax}\ p[i]\}$ 表示伪标签为 i、真实标签为 j 的样本集。

④标准化计数矩阵。由于计数总数可能与 $\hat{Y}$ 标记样本总数不同，因此需要对其加权标准化以确保计数矩阵元素之和等于 $\hat{Y}$ 标记样本总数，标准化

后的计数矩阵 $\widetilde{\boldsymbol{C}}_{\hat{Y},Y^*}$ 元素表示为

$$\widetilde{C}_{\hat{Y},Y^*}[i][j]=\frac{C_{\hat{Y},Y^*}[i][j]}{\sum_{j=1}^{k}C_{\hat{Y},Y^*}[i][j]}|X_{\hat{Y}=i}| \tag{4}$$

式中 $|X_{\hat{Y}=i}|$——$\hat{Y}$ 取到标签 i 的样本总数

对 $\widetilde{\boldsymbol{C}}_{\hat{Y},Y^*}$ 归一化，得到联合分布矩阵 $\hat{\boldsymbol{Q}}_{\hat{Y},Y^*}$

$$\hat{\boldsymbol{Q}}_{\hat{Y},Y^*}[i][j]=\frac{\widetilde{C}_{\hat{Y},Y^*}[i][j]}{\sum_{i=1}^{k}\sum_{j=1}^{k}\widetilde{C}_{\hat{Y},Y^*}[i][j]} \tag{5}$$

(2)基于置信度找出并过滤低置信度样本

得到伪标签和 SVM 预测标签的联合分布后，采用按类别筛选法[28]找出伪标签中的低置信度样本。对于每个类 $j\in\{1,2,\cdots,k\}$，首先对满足 $\hat{Y}=j$ 的所有预测概率 $p[i][j]$ 排序，选出 $n\sum_{1\leqslant j\leqslant k,j\neq i}\hat{\boldsymbol{Q}}_{\hat{Y}=i,Y^*=j}[i]$ 个具有最低置信度的样本作为不可信样本并将其过滤。通过这种方法获得了置信样本 $\hat{Y}_C\in\hat{Y}$。

(3)过滤后的样本加入下一轮重训练

由于低置信度的样本被按类别过滤，因此类别之间置信样本的数量可能不同。为了平衡类分布，根据联合分布 $\hat{\boldsymbol{Q}}_{\hat{Y},Y^*}$ 修正类别 i 的损失权重

$$\boldsymbol{\omega}_{\text{confident}_{\text{class}}}=\frac{\widetilde{Q}_{Y^*}[i]}{\widetilde{Q}_{\hat{Y},Y^*}[i][i]} \tag{6}$$

然后，利用过滤后的样本替换集成模型得到的伪标签，并输入集成学习模块和 SVM 进行下一轮训练。$\boldsymbol{\omega}_{\text{confident}_{\text{class}}}$ 用来对每个深度学习模型的损失函数重新加权。这样就实现了利用少量样本的迭代优化，逐渐细化伪标签直到精度达到稳定。

1.4 实现过程

为了充分利用集成分类结果中的置信样本，提高模型的分类性能，ECL－SSCF 模型的训练过程包括集成学习和置信学习 2 个部分。在初始训练阶段，没有集成分类结果中的置信样本。因此，首先使用少量的已标记数据集 $\{X_l,Y_l\}$ 来训练集成学习模块。经过训练世代(epoch)train_num，得到伪标签。通过置信学习，选择高置信伪标签 $\{X_c,\hat{Y}_c\}$ 而不是所有伪标签作为样本加入模型训练。获得了置信标签，就可以迭代交替训练集成学习模块和置信学习模块。

一方面，将集成学习训练过程分为 2 个步骤。首先，为了提升少量样本深度学习模型的分类性能，利用少量的标记样本并行训练 4 个深度学习模型 LSTM、Conv1D、ConvLSTM、TempCNN。考虑到训练样本集类别不平衡问题，4 个深度学习模型均采用了聚焦损失函数(Focal loss)[29]，可表示为

$$L_{FL}=-\sum\alpha_i(1-p_i)^{\gamma}\ln(p_i) \tag{7}$$

式中 p_i——第 i 类的预测概率

α_i——第 i 类的调整因子

γ——调整样本权重的参数

其次，将 LSTM、Conv1D、ConvLSTM、TempCNN 的分类结果以相对众数投票的方式集成得到伪标签 $\hat{Y}$。需要注意的是，相对众数投票集成的结果 $\hat{Y}$ 不参与 4 个深度学习模型的梯度反向传播。

另一方面，利用置信学习寻找高置信度的伪标签，并使用高置信度的伪标签进一步训练集成学习模块，避免少量样本导致的模型过拟合。在集成学习模块得到了所有的伪标签 $\hat{Y}$。然后，利用少量的标记样本对 SVM 分类器进行交叉验证，得到预测概率 P 和真实标签 Y^*。用 $\hat{Y}$ 和 Y^* 对每个类别的样本数进行计数，得到计数矩阵 $\boldsymbol{C}_{\hat{Y},Y^*}$。对 $\boldsymbol{C}_{\hat{Y},Y^*}$ 归一化得到联合分布矩阵 $\hat{\boldsymbol{Q}}_{\hat{Y},Y^*}$。通过 $\hat{\boldsymbol{Q}}_{\hat{Y},Y^*}$ 计算出类的权值 $\boldsymbol{\omega}_{\text{confident}_{\text{class}}}$，过滤掉不可信的标签，得到下一阶段训练的可信标签。

整个训练过程为：

输入：少量的标记样本 X_l,Y_l，训练总 epoch 数 *num*，开始置信学习前的训练 epoch 数 train_num。

输出：4 个深度学习模型的分类结果和相对众数投票结果。

begin

1 利用高斯分布函数初始化 LSTM、Conv1D、ConvLSTM、TempCNN。

2 FOR epoch in {1,2,…,num} do

集成学习

3 if epoch≥train_num，基于方程式(7)更新参数 α_i 和 γ。

4 利用相对众数投票法集成 LSTM、Conv1D、ConvLSTM、TempCNN 的分类结果。

置信学习

5 if epoch% train_num = =0

6 获得伪标签 $\hat{Y}$ 和预测概率 P。

7 通过方程式(3)获得置信计数矩阵 $\boldsymbol{C}_{\hat{Y},Y^*}$。

8 通过方程式(5)获得联合分布矩阵 $\hat{\boldsymbol{Q}}_{\hat{Y},Y^*}$。

9 找出不可信的伪标签。

10 清除不可信的标签获得可信标签。

11 利用高置信样本训练集成学习模型。

12 END FOR

2 应用验证

2.1 研究区

选择湖北省枝江市和山东省桓台县作为研究区(图 2)，验证 ECL－SSCF 模型的精细作物分类性能。枝江市位于湖北省中部(30°16′～30°40′N，

111°25′～112°03′E)，总面积为 1 310 km²，属亚热带季风气候，热量丰富，雨量充沛。农作物以冬小麦、冬油菜和柑橘为主。冬小麦在 10 月末至 11 月播种，次年 6 月收获。冬油菜 10 — 11 月播种，次年 5 月收获。桓台县位于山东省中部偏北(36°51′～37°06′N，117°50′～118°10′E)，总面积为 509 km²，属于暖温带大陆性季风气候区，四季分明，雨热同期，地处华北平原，土壤肥沃，是典型的旱地农业种植区。农作物主要是冬小麦、蔬菜和果树，主要蔬菜类型为大蒜。冬小麦和大蒜都在 10 月初播种，次年 6 月收获。2 个研究区主要作物物候期见图 3。相对于桓台县，枝江市的农作物种植结构相对复杂，尤其是地块比较破碎。因此，这 2 个地区在种植结构上均具有一定的典型性，选择其作为本研究方法的应用验证区，对于后续方法的应用推广和改进都具有一定的参考价值。

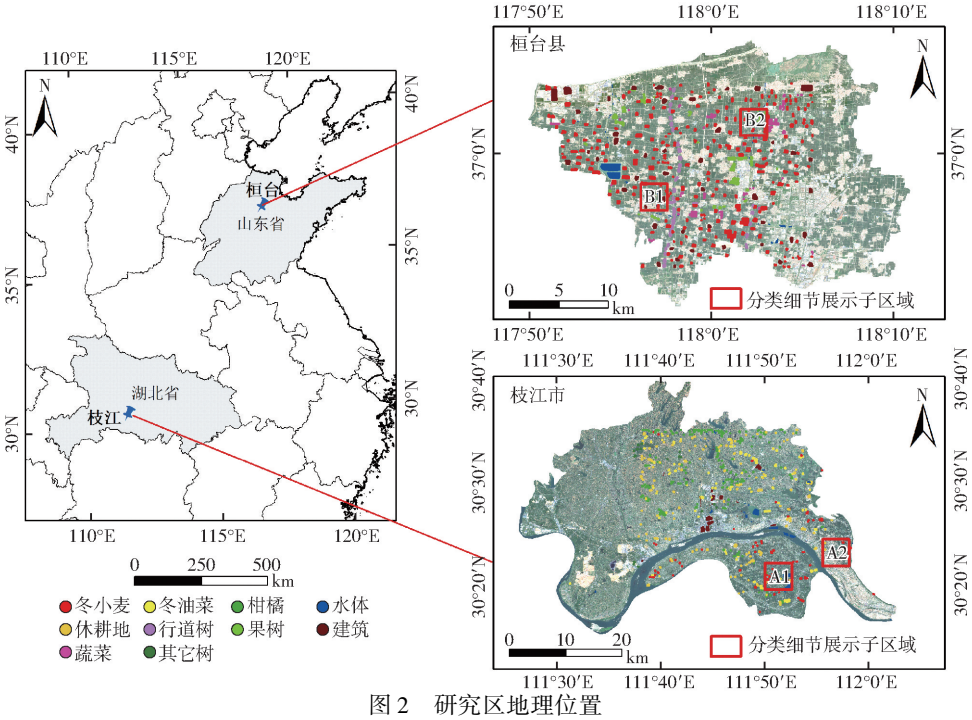

图 2　研究区地理位置

Fig. 2　Geographical location of study areas

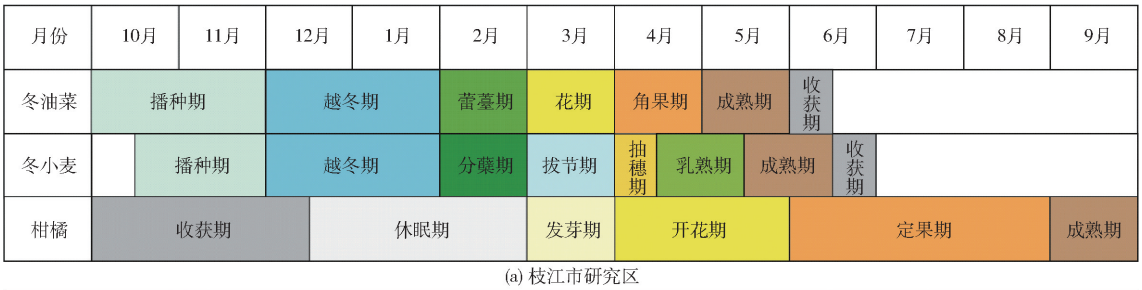

(a) 枝江市研究区

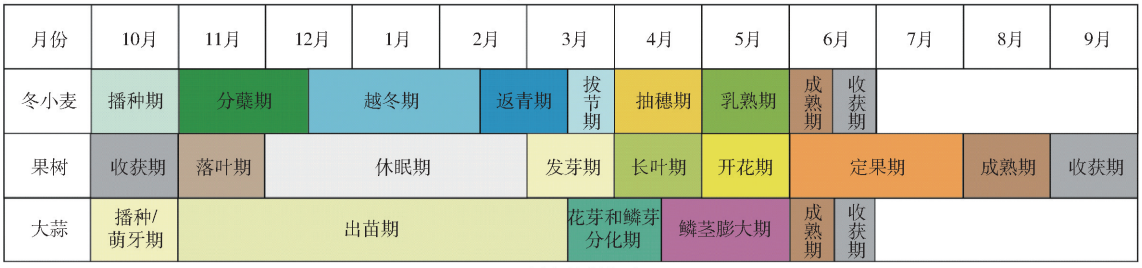

(b) 桓台县研究区

图 3　2 个研究区主要农作物物候期

Fig. 3　Phenological conditions of different crops at each study site

2.2　数据

2.2.1　遥感数据

基于 Google Earth Engine 平台，实验采用 Sentinel－2 Level－2A 地表反射率(SR)数据。为能覆盖冬小麦整个生长季，获取了 2021 年 9 月至 2022 年 5 月枝江市和桓台县云量小于 20% 的所有可用

影像。通过镶嵌、裁剪处理,按照陆表遥感不同地物在不同波段的反射率特征,选取 Blue(B2)、Green(B3)、Red(B4)、Red Edge 1(B5)、Red Edge 2(B6)、Red Edge 3(B7)、Near-infrared(B8)、Red Edge 4(B8A)、SWIR 1(B11)、SWIR 2(B12)共 10 个波段数据,并将像素的空间分辨率统一到 10 m 用于作物分类。2 个研究区获取的可用影像分别为 8 景和7 景,具体日期如表 1 所示。

表 1 枝江市和桓台县 Sentinel-2 影像选用日期

Tab. 1 Date information of Sentinel-2 image of Zhijiang and Huantai

影像序号	枝江市	影像序号	桓台县
1	2021 年 10 月 4 日	1	2021 年 11 月 10 日
2	2021 年 11 月 13 日	2	2021 年 12 月 5 日
3	2021 年 12 月 23 日	3	2022 年 1 月 29 日
4	2022 年 3 月 8 日	4	2022 年 2 月 23 日
5	2022 年 4 月 2 日	5	2022 年 3 月 5 日
6	2022 年 4 月 7 日	6	2022 年 4 月 4 日
7	2022 年 5 月 2 日	7	2022 年 4 月 19 日
		8	2022 年 5 月 4 日

2.2.2 样本数据

参考数据包括野外样本数据集和目视解译数据。野外样本数据为 2022 年 5 月 19—21 日在湖北枝江市和 2022 年 6 月 6—7 日在山东省桓台县采集的 GPS 样本数据。枝江市样本数据共 30 个,其中冬小麦 10 个、冬油菜 10 个、柑橘树 10 个。桓台县样本数据共 21 个,其中冬小麦 11 个、蔬菜 8 个、果树 2 个。在野外样本数据基础上,继续借助桓台县 2022 年 5 月 4 日、5 月 27 日和枝江市 2022 年 4 月 8 日 GF-2 PMS 2 m 高分辨率光学影像,以及 Google Map 为辅助数据,目视解译提取了两地的样本。在枝江市增加了其它树的样本以和柑橘树区分,同时,在桓台县增加了行道树样本以和果树区分。其中枝江市和桓台县目视解译样本数据分别为 618 和 499 个。因此,枝江市和桓台县的总样本量分别为 648 和 520 个,其分布情况如图 2 所示,各地物类别样本数量如表 2 所示。为了验证少量样本情景下的 ECL-SSCF 的分类性能,样本集分类别按比例 1∶1分成训练集与测试集,训练集用来训练分类模型,测试集用来评估模型最终的分类性能,2 个数据集彼此之间独立。

2.3 模型训练与评价

当 ECL-SSCF 模型在 2 个研究区分别迭代训练超过 5 次时,对应结果已经稳定,因此,取前 5 次作为本研究的应用验证结果进行分析。对应进行置信学习前训练世代数(epoch)为50,总训练世代数为 250。在初次训练中,LSTM、Conv1D、ConvLSTM、TempCNN 和 SVM 在枝江市和桓台县所有地物类别样本总和分别取 324 个和 260 个。所有实验都在 Pytorch 框架下实现,使用 GDAL 库进行图像处理。4 种深度学习模型都使用自适应矩估计(Adaptive moment estimation, Adam)优化器进行训练。Adam 的参数固定为:$\beta_1 = 0.9$,$\beta_2 = 0.999$,$\varepsilon = 1 \times 10^{-5}$,学习率为 0.001,学习率衰减为 0.001。批次大小为 256(pixels)。4 种模型的其它超参数设置和优化基于文献[16,30]。SVM 的核函数采用径向基函数在 Scikit-learn 中训练,其他参数采用默认设置。

表 2 枝江市和桓台县 2022 年各地物类别样本数量

Tab. 2 Number of samples by category in Zhijiang and Huantai in 2022

枝江市				桓台县			
类别	野外样本	目视解译样本	总计	类别	野外样本	目视解译样本	总计
冬油菜	10	46	56	冬小麦	11	43	54
冬小麦	10	102	112	蔬菜	8	62	70
柑橘树	10	114	124	果树	2	78	80
休耕地	0	128	128	建筑	0	100	100
水体	0	96	96	水体	0	100	100
建筑	0	80	80	行道树	0	116	116
其它树	0	52	52				
总计	30	618	648	总计	21	499	520

分类性能通过总体精度(Overall accuracy, OA)、Kappa 系数(KP)、用户精度(User's accuracy, UA)、制图精度(Producer's accuracy, PA)以及 F1 分数进行评价[31]。

3 结果

3.1 基于 ECL-SSCF 的样本精度

图 4 是 ECL-SSCF 前 5 次迭代训练获得的样本的分类结果,每次的分类结果都利用置信学习策略按类别筛选法进行了低置信度样本过滤,被过滤掉的样本标记为“未标注”。从图 4 可以看出,第 1 次训练利用少量的人工标记样本,经过置信学习策略对低置信度样本过滤后,枝江市和桓台县 2 个研究区样本的 OA 分别为 70.85% 和 76.5%,模型预测性能不理想,于是继续进行半监督训练。样本的 OA 预测精度在初次利用极少量样本训练的基础上逐渐提升,在第 4 轮迭代后 2 个研究区 OA 相对于第 3 轮训练趋于稳定,第 5 轮迭代后的 OA 和 KP 相对于第 4 轮已基本一致,枝江市和桓台县 2 个研究区的 OA 较初次训练分别提升了 17.15 个百分点和 9.33 个百分点。同时,未标记样本逐渐减少,说明样本数量得到扩充。

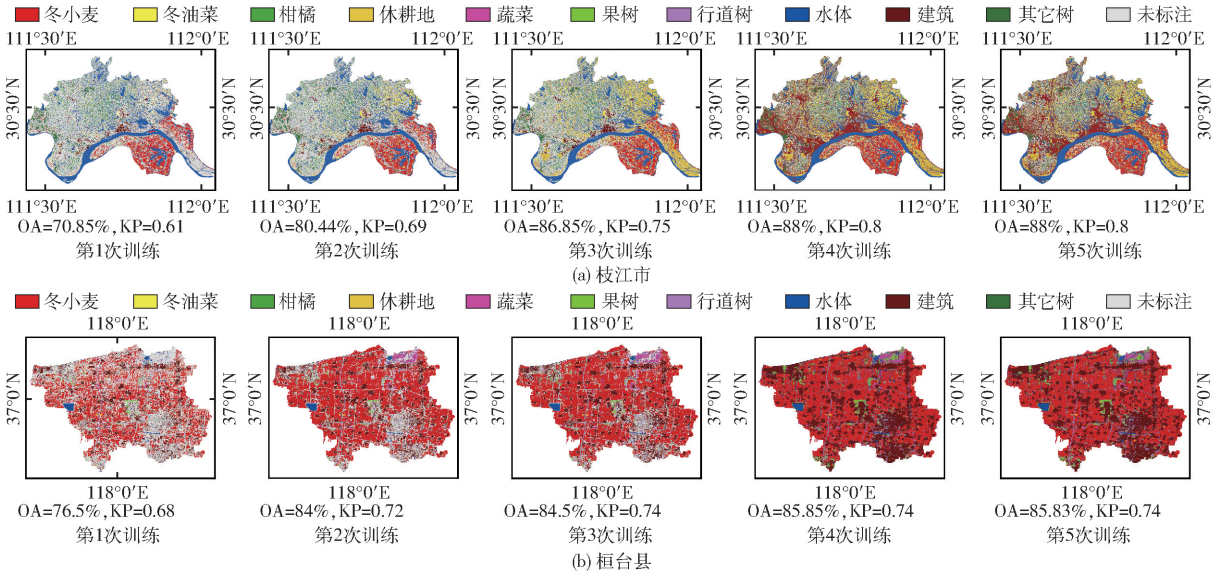

图 4　ECL－SSCF 预测的伪样本空间分布和精度

Fig. 4　Spatial distributions and accuracy of pseudo-samples predicted by ECL－SSCF

表 3 进一步展示了 ECL－SSCF 和 LSTM、Conv1D、ConvLSTM、TempCNN 4 种单深度学习模型在半监督分类框架下得到的样本精度。ECL－SSCF 每轮训练得到的样本精度都高于 4 种单深度学习模型。LSTM 初始训练得到的样本精度高，但精度提升速度低于其它 4 种模型。有可能是因为较简单的模型结构，使 LSTM 对于样本量的需求比 Conv1D、ConvLSTM 和 TempCNN 低，但正是因为简单的模型结构使 LSTM 的特征表示能力低于其它 3 种模型，从而导致了较低的精度提升速度。总体来说，ECL－SSCF 通过半监督学习的迭代训练，样本的数量和质量得到了扩充和提升。

表 3　ECL－SSCF 和 4 种单一深度学习模型得到的样本精度

Tab. 3　Sample accuracy from ECL－SSCF and four single deep learning models

研究区	训练轮次	LSTM		Conv1D		ConvLSTM		TempCNN		ECL－SSCF	
		OA/%	KP	OA/%	KP	OA/%	KP	OA/%	KP	OA/%	KP
枝江市	1	65.1	0.58	63.7	0.57	63.1	0.55	64.0	0.55	70.9	0.61
	2	72.2	0.62	74.0	0.63	73.2	0.65	75.0	0.64	80.4	0.69
	3	82.5	0.72	83.1	0.73	84.0	0.74	83.8	0.73	86.9	0.75
	4	83.1	0.76	83.8	0.76	84.5	0.77	84.3	0.76	88.0	0.80
	5	83.0	0.76	83.8	0.76	84.4	0.77	84.4	0.76	88.0	0.80
桓台县	1	71.1	0.62	69.0	0.58	68.5	0.58	69.0	0.60	76.5	0.68
	2	75.6	0.64	73.9	0.67	72.7	0.67	74.1	0.69	84.0	0.72
	3	79.5	0.68	80.0	0.69	82.2	0.71	81.5	0.71	84.5	0.74
	4	80.4	0.68	81.9	0.71	82.3	0.72	82.2	0.72	85.9	0.74
	5	80.2	0.68	82.0	0.71	82.3	0.72	82.4	0.72	85.8	0.74

3.2　ECL－SSCF 的作物分类精度

对半监督学习第 5 轮的预测结果未进行置信学习操作，作为最终的分类结果定量和定性评价 ECL－SSCF 和4 种单深度学习模型的作物分类性能。

表 4 总结了枝江市 ECL－SSCF 和 4 种单深度学习模型对 7 种地物类型的精度评估。将模型的 OA 高于 80% 定义为良好。各模型总体较好，OA 为 85.41% ~90.43%。ECL－SSCF 具有最好的性能，OA 为 90.43%。由于 4 个单深度学习模型的原理不同，ECL－SSCF 方法综合利用了它们的优势，相互补充，最终提高了作物的分类精度。4 个单深度学习模型中，OA 最高（TempCNN）和最低（LSTM）值的差为 2.36 个百分点，说明 4 种深度学习模型性能的多样性较高，有利于相对多数投票的进行。在各作物类型的 F1 分数比较中，ECL－SSCF 明显优于 4 种单深度学习模型。冬小麦和冬油菜 2 种作物的 F1 分数均大于 90%。

表 5 为桓台县 ECL－SSCF 和 4 种单深度学习模型对 7 种地物类型的精度评估。各模型的 OA 为 81.54% ~86.26%。ECL－SSCF 具有最好的性能，OA 最高为 86.26%。4 个单深度学习模型中，

表 4 各模型在枝江市的精度

Tab. 4 Accuracy of each model in Zhijiang %

模型	指标	各类别精度							OA
		冬油菜	冬小麦	柑橘树	休耕地	水体	建筑	其它树	
LSTM	PA	86.67	86.21	84.75	83.87	93.88	92.86	62.07	85.41
	UA	70.27	94.34	80.65	96.30	92.00	82.98	69.23	
	F1 分数	77.61	90.09	82.64	89.66	92.93	87.64	65.45	
Conv1D	PA	90.00	86.21	89.47	83.33	95.92	86.67	64.29	86.24
	UA	81.82	96.15	80.95	90.91	90.38	82.98	72.00	
	F1 分数	85.71	90.91	85.00	86.96	93.07	84.78	67.92	
ConvLSTM	PA	93.33	89.66	89.66	83.33	94.00	86.67	71.43	87.54
	UA	82.35	96.30	85.25	92.59	90.38	82.98	74.07	
	F1 分数	87.50	92.86	87.39	87.72	92.16	84.78	72.73	
TempCNN	PA	96.43	91.38	86.21	85.00	92.16	88.89	70.37	87.77
	UA	79.41	96.36	86.21	94.44	92.16	81.63	73.08	
	F1 分数	87.10	93.81	86.21	89.47	92.16	85.11	71.70	
ECL－SSCF	PA	100	89.29	87.10	87.50	100	97.50	69.23	90.43
	UA	82.35	100	85.71	100	94.12	88.64	69.23	
	F1 分数	90.32	94.34	86.40	93.33	96.97	92.86	69.23	

表 5 各模型在桓台县的精度

Tab. 5 Accuracy of each model in Huantai %

模型	指标	各类别精度						OA
		冬小麦	蔬菜	果树	建筑	水体	行道树	
LSTM	PA	95.83	80.56	65.00	93.75	96.00	65.52	81.54
	UA	79.31	90.63	56.52	86.54	100	77.55	
	F1 分数	86.79	85.29	60.47	90.00	97.96	71.03	
Conv1D	PA	95.83	88.89	67.50	95.83	98.00	67.24	84.29
	UA	92.00	91.43	57.45	90.20	100	78.00	
	F1 分数	93.88	90.14	62.07	92.93	98.99	72.22	
ConvLSTM	PA	100	88.57	68.29	95.83	96.08	70.69	85.44
	UA	92.31	93.94	60.87	92.00	100	78.85	
	F1 分数	96.00	91.18	64.37	93.88	98.00	74.55	
TempCNN	PA	95.83	85.71	68.29	97.96	98.00	68.97	85.44
	UA	92.00	90.91	59.57	92.31	100	80.00	
	F1 分数	93.88	88.24	63.64	95.05	98.99	74.07	
ECL－SSCF	PA	100	88.89	70.00	100	100	65.52	86.26
	UA	90.00	100	60.87	92.59	100	79.17	
	F1 分数	94.74	94.12	65.12	96.15	100	71.70	

TempCNN 和 ConvLSTM 都取得了 OA 最高值(85.44%),而 LSTM 的 OA 值(81.54%)最低。在各种地物类型的 F1 分数比较中,ECL－SSCF 明显优于 4 种单深度学习模型。总体来说,ECL－SSCF 与 4 种单深度学习模型相比具有最高的精度。

图 5 是枝江市 ECL－SSCF 的分类结果。冬小麦、冬油菜主要种植在枝江的东部,最东部长江北岸有大量休耕地,可能是为种植早稻准备的田块;西部主要以柑橘树和其它树为主,夹杂种植少量的冬油菜和冬小麦。图 6 展示了桓台县 ECL－SSCF 的分类结果,桓台县主要的作物为冬小麦,其次是蔬菜、果树。图 7 为所有模型在枝江市和桓台县图 2 红框区域的分类结果,A1、A2 位于枝江市,B1、B2 位于桓台县。ECL－SSCF 的分类结果和影像中的地物类别表现出高度的一致性。相反,LSTM 在 4 个子区域对冬小麦均表现为错分,如在 A1 子区域将柑橘和建筑分为冬小麦,在 A2 子区域将休耕地分为冬小麦,在 B1 和 B2 子区域将行道树和蔬菜分为冬小麦。而 Conv1D 在 4 个子区域均表现为对冬小麦的漏分。ConvLSTM 和 TempCNN 的分类结果相似度较高。总体来说,ECL－SSCF 可以更有效地区分分布比例较小的作物类型,如 A2 子区域的休耕地和 B2 子区域的蔬菜和果树。

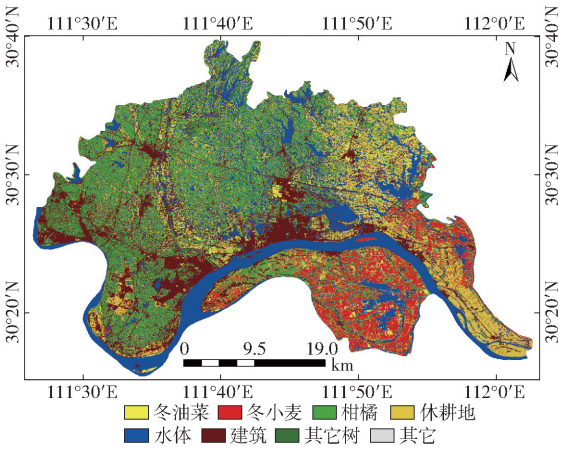

图 5　ECL－SSCF 在枝江市的分类结果

Fig. 5　Classification results of ECL－SSCF in Zhijiang

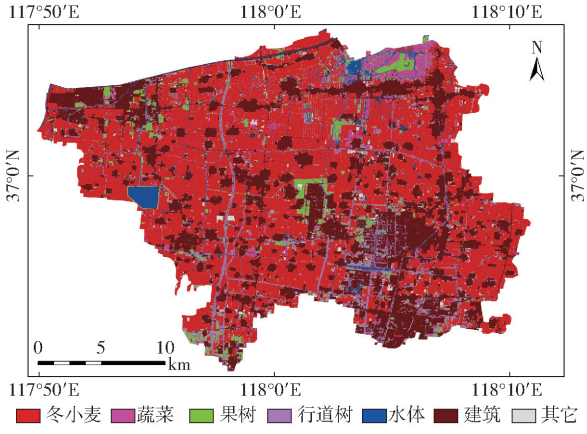

图 6　ECL－SSCF 在桓台县的分类结果

Fig. 6　Classification results of ECL－SSCF in Huantai

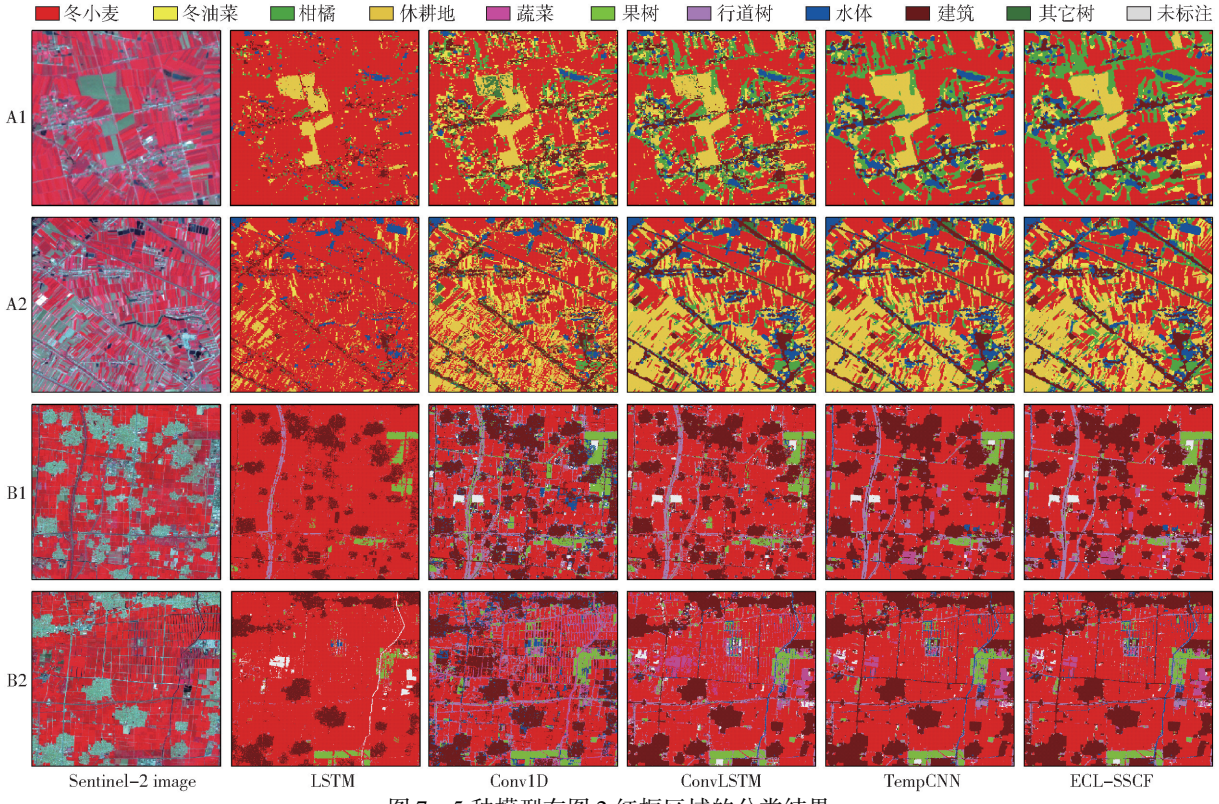

图 7　5 种模型在图 2 红框区域的分类结果

Fig. 7　Classification results of five models in red box area of Fig. 2

4　讨论

4.1　训练样本数量和质量对各模型性能的影响

训练样本的数量和质量是影响深度学习模型准确率的重要因子[32]，因此，在 ECL－SSCF 框架下进一步定量评价了训练样本量和纯度对深度学习模型性能的影响。基于第 4 轮半监督学习的结果作为标准样本集，由于两个研究区内不同的作物类型分布比例的差异，为了保证小比例的地物类型（如桓台县的蔬菜和果树）也能够获得等比例的样本数量，本研究采用分层随机抽取不同数量（1%、5%、10%、15%、20%、25%、30%、35%、40%、45%、50%）的训练样本，训练 LSTM、Conv1D、ConvLSTM、TempCNN 和 ECL－SSCF 5 种模型进行分类。

如图 8 所示，5 种模型的验证指标随着所有类别的样本量按比例增加而迅速提高，各模型验证指标的提升速率不同，但都在样本量达到 30% 左右时减慢，LSTM 的验证指标趋于稳定，Conv1D、ConvLSTM、TempCNN 和 ECL－SSCF 4 种模型的验证指标还有小幅度提升。LSTM 模型的性能对样本量的增加不如 Conv1D、ConvLSTM、TempCNN 模型敏感，这说明这 3 种模型对样本数量的需求可能更大。ECL－SSCF 模型相对于其它 4 种模型的预测精度变化趋势更平稳。在桓台县，由于种植结构简

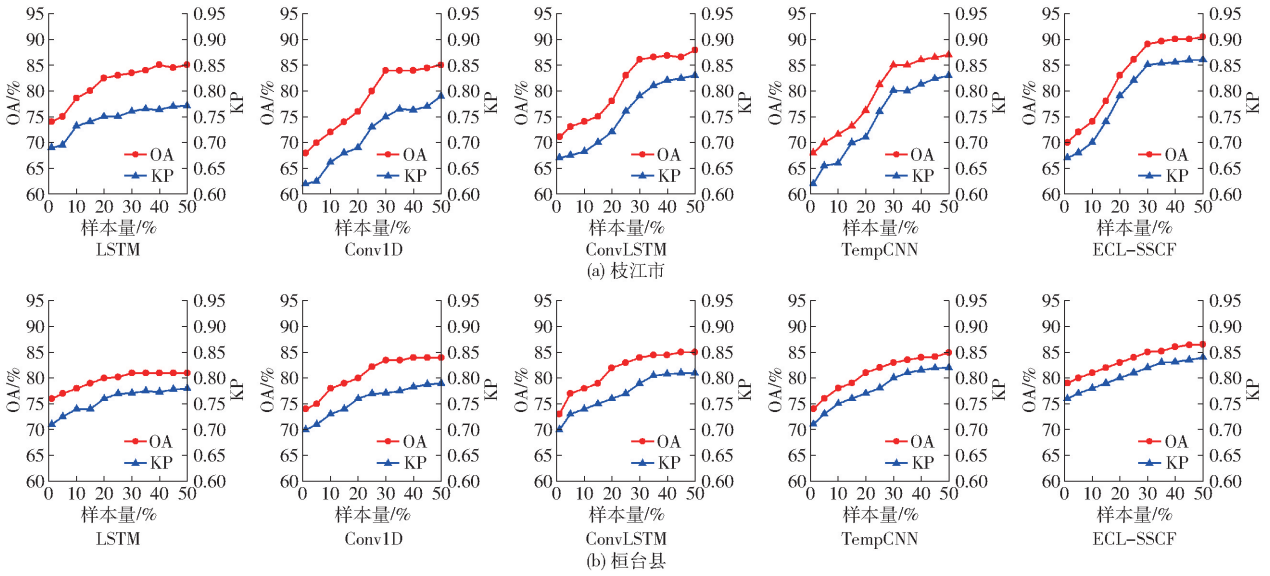

图 8 各模型在 2 个研究区不同比例训练样本下的 OA 和 KP 变化曲线

Fig. 8 Curves of OA and KP changes of various models under different proportions of training samples in two study areas

单,主要的农作物为冬小麦,随着训练样本数量的逐步增加,验证指标保持相对稳定;枝江市具有复杂的种植结构和破碎的地块,随着训练样本数量的变化,验证指标有更大的波动。这说明在复杂种植结构下,训练样本数量是导致深度学习模型性能低的一个重要因素。总体来说,在相同的样本数量下,ECL-SSCF 的分类精度最高。

此外,本研究通过在标准样本集中添加高斯随机噪声来检验训练样本纯度对各模型准确性的影响。高斯噪声因其广泛存在于自然界中,因此被选作模拟噪声的主要类型。引入高斯随机噪声的主要目的是为了模拟遥感图像在实际获取过程中可能遇到的各种噪声干扰,如传感器噪声、大气条件变化等[33],进而评估 ECL-SSCF 对噪声的鲁棒性。高斯噪声(Gaussian noise)是一种概率密度函数服从高斯(正态)分布的噪声,其数学模型可以表示为

$$p(z)=\frac{1}{\sqrt{2\pi}\sigma}e^{\frac{-(z-\mu)^2}{2\sigma^2}} \tag{8}$$

式中 z——像元灰度(噪声值)

μ——z 的平均值,设置为 0

σ——z 的标准差,根据实验设计赋予不同的值以模拟不同程度的噪声污染

在实验中,通过在标准样本集所对应原始遥感影像的像素上添加高斯噪声来模拟实际数据中的不确定性。具体地,对于影像中需要添加噪声的每一个像素 x,生成一个高斯噪声值 n_0,并将其加到 x 上,得到新的噪声像素 $x'=x+n_0$。具体来说,在 10% ~50% 的范围内,以 5% 为步长分层随机引入噪声像素。图 9 显示了加入噪声前后图像的直观对比。图 9a 为未经处理的 2022 年 5 月 4 日桓台县子区域 B2 的原始 Sentinel-2 影像的近红外波段,图 9b ~9j 为在标准样本集所对应原始影像的基础上以步长为 5% 加入高斯噪声(即 $\sigma=5\%$)生成的噪声影像。通过对比加噪声前后影像,可以发现随着随机噪声量增加,噪声影像的对比度和亮度都有明显下降。

图 10 进一步说明,随着各类地物样本中噪声像素比例的增加,所有模型的性能均有下降。在桓台县,随着噪声样本数量的逐步增加,2 项验证指标下降速率相对缓慢,这表明各模型都受益于桓台县的简单种植结构。当各类训练样本的噪声比例增加到 40% 及以上时,5 种模型的准确性均急剧下降,KP 降到 0.5 以下,几乎无法进行农作物分类。LSTM 的精度最低(46%),说明其相对于其它 4 种模型抗噪声能力更低。尽管如此,相对于 4 种单深度学习模型,ECL-SSCF 在样本噪声比例保持在 30% 以下时,评价指标仅有小幅下降(OA 大于 85%,KP 大于 0.8)。ECL-SSCF 模型通过置信学习策略提纯的样本表现出很强的抗噪能力。

这一发现的意义体现在以下几方面:首先,较低的噪声样本比例意味着伪样本中高质量样本的比例较高,这有助于提升模型的分类精度和稳定性。其次,在样本数量有限的情况下,过多的噪声样本会导致模型过拟合,降低其在测试集上的性能,在农业遥感分类的实际应用中,获取大范围和高质量的标注样本往往成本高昂且耗时。因此,通过引入适量的噪声样本并控制其比例,可以在保证分类精度的同时,降低对高质量标注样本的依赖。最后,通过进一步分析样本数量和噪声样

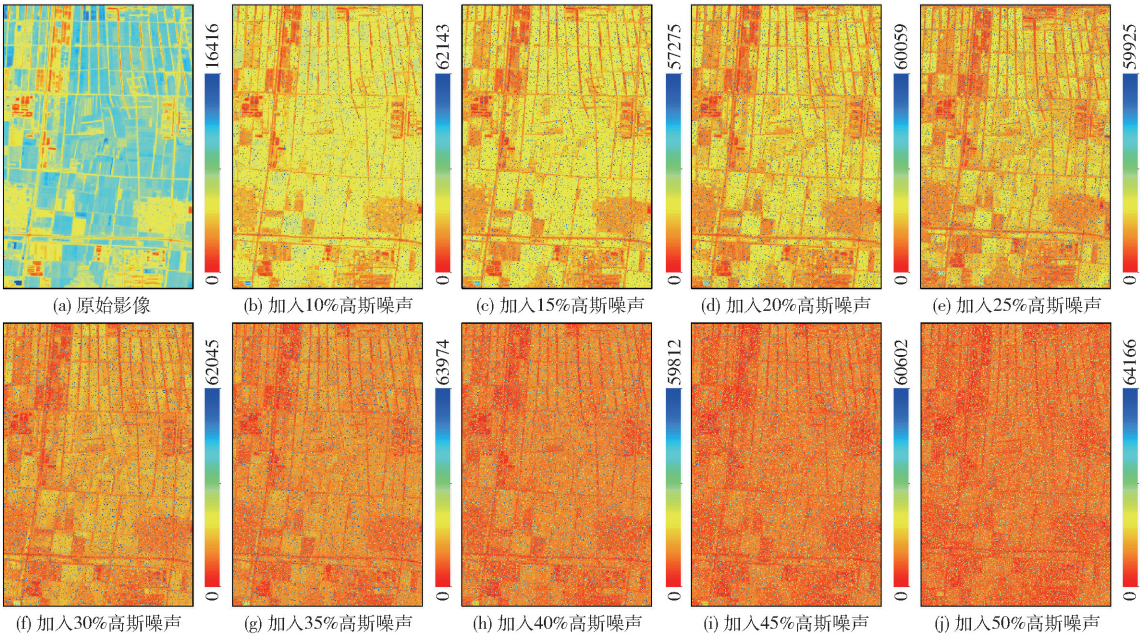

图 9　原始 Sentinel－2 影像的近红外波段和加入高斯噪声的影像对比

Fig. 9　Comparison between near-infrared band of original Sentinel－2 image and image with Gaussian noise

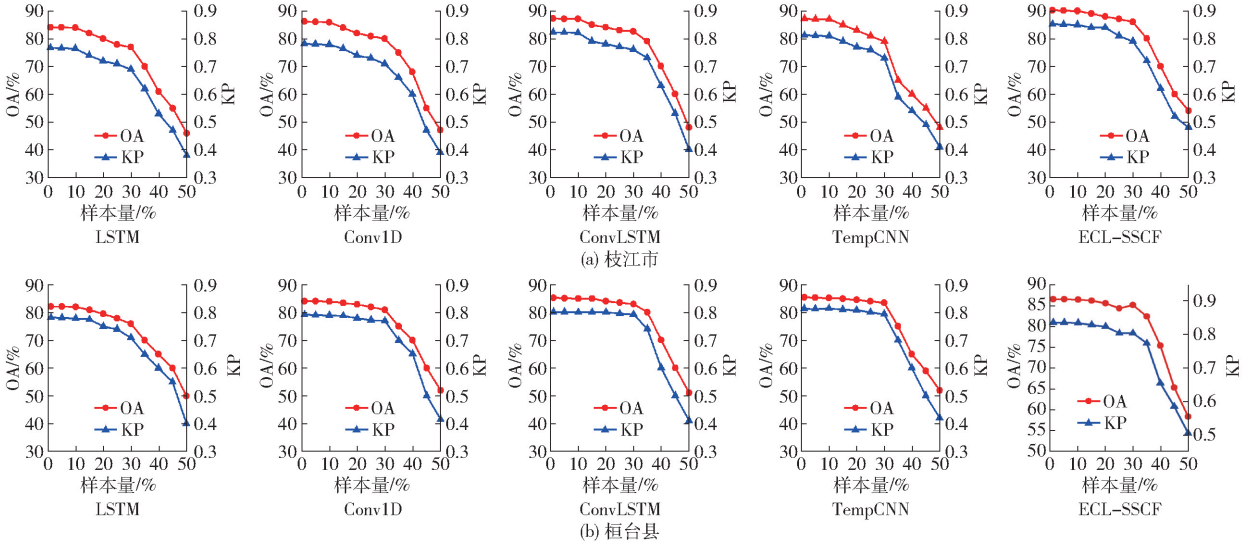

图 10　各模型在 2 个研究区不同比例噪声样本下的 OA 和 KP 精度变化曲线

Fig. 10　Curves of OA and KP accuracy changes of various models under different proportions of noisy samples in two study areas

本比例对模型性能的影响，实验结果表明，当样本数量达到标准样本集的 30% 左右，噪声样本比例控制在 30% 以下时，模型的分类精度和鲁棒性均能保持在一个较高水平。这一发现提供了一个平衡样本数量和质量的量化参考，优化了模型的训练过程，对于实际应用中遥感图像的预处理和噪声抑制具有重要的指导意义。

4.2　ECL－SSCF 对不同作物分类精度分析

对 ECL－SSCF 第 5 轮的预测结果未继续进行置信学习操作，进一步探究 ECL－SSCF 对于不同类别作物识别性能的不确定性。

在枝江市研究区（图 11a），对不同作物来说，冬小麦是分类精度最高的农作物，但它和冬油菜有一定程度的混分，其中 10% 的冬小麦被错误分类为冬油菜，冬油菜没有被误分为冬小麦，这是由于这 2 类农作物有十分相似的物候期。休耕地可能由于具有明显的耕地形状却没有植被信息干扰，表现了较高的精度。柑橘树和其它树之间存在一定的混分，通过对照 GF－2 高分辨率影像发现，有一些柑橘树林比较茂密，已经没有明显的人工种植形成的成排成列的纹理，从而被误分为其它树。对于不同模型来说（表 4），ConvLSTM 在柑橘和其它树的识别上分别表现了最高的 F1 分数（87.39% 和 72.73%），但 ECL－SSCF 的柑橘和其它树的 F1 分数分别为 86.40% 和 69.23%，说明在柑橘和其它树的投票结果中 LSTM、Conv1D 和 TempCNN 3 个模型的结果获

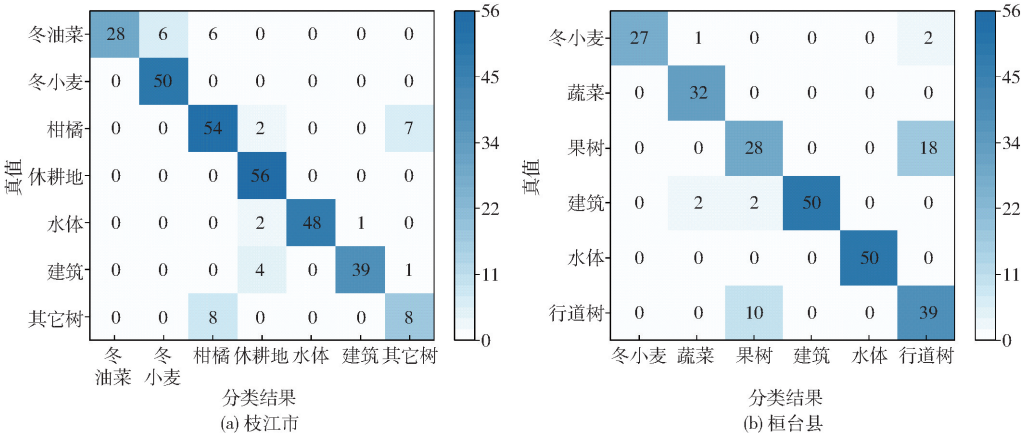

图 11 ECL－SSCF 在枝江产市和桓台县分类结果的混淆矩阵

Fig. 11 Confusion matrixes of ECL－SSCF classification results in Zhijiang and Huantai

得了投票权。

在桓台县研究区(图 11b),冬小麦的分类精度较高,但有少量的蔬菜被错分成冬小麦。经调查,桓台县主要的蔬菜为大蒜,由于冬小麦和大蒜的混种,Sentinel 2 较低的空间分辨率使得冬小麦与大蒜像元容易混淆。同时,冬小麦和大蒜生育期接近、光谱响应相似,特别是春季生长期,采用原始波段数据分离两者的难度较大,需要提高遥感数据分辨率、添加植被指数波段来进一步提高冬小麦和大蒜的识别精度。少量建筑物被错分成了蔬菜和果树,这是由于蔬菜和果树的种植区接近居民区且种植面积相对较小。行道树和果树也互相混分,说明 Sentinel 2 数据对于区分混种的树种还是会受混合像元的影响。和枝江市的精度类似,水体和建筑都有较高的精度。对于不同模型(表 5),ConvLSTM 在冬小麦识别上表现了最高的 F1 分数(96%),但 ECL－SSCF 的 F1 分数为 94.74%,说明在桓台县的冬小麦投票结果中,LSTM、Conv1D 和 TempCNN 3 个模型的结果获得了投票权。另外,虽然桓台县的种植结构相对简单,本文评价分类结果的参考样本也采取了分层随机抽样,但仅有主要作物冬小麦的 F1 分数较高,其他少数地物类型(如果树和行道树)仍然存在较明显的错分和漏分,导致总体分类精度反而低于枝江市。

4.3 未来工作

ECL－SSCF 模型利用少量的标注样本,采用半监督学习方法,集成 4 种深度学习模型进行了多作物分类并取得了满意的精度,但是 ECL－SSCF 仍有以下不确定性:

(1)10 m 分辨率对于作物的精细分类,尤其在具有相似物候期的作物混种区(如枝江市的冬小麦和冬油菜,桓台县的冬小麦和大蒜)还是会产生混合像元,从而导致这些作物的错误分类。在未来的研究中应该融合更高分辨率的数据,使模型能充分挖掘出高/低分辨率影像在空间和时间维度上对作物分类的贡献。

(2)以往的许多研究普遍认为集成学习算法将多个分类模型聚集在一起,使模型性能更加稳定,降低过拟合的风险,并获得比单一分类器更高的分类性能[34－35]。本文也证实了集成学习可以获得更可靠的作物分类结果。但是,相对众数投票方法选择被大多数模型预测的类标签作为最终的分类结果,如果多数模型对某些类别的识别能力较低,如 LSTM、Conv1D 和 TempCNN 3 个模型在枝江市的柑橘和其它树的 F1 分数均低于 ConvLSTM,这个结果导致 ECL－SSCF 的柑橘和其它树的 F1 分数也低于 ConvLSTM。这说明同质性高的低性能单一深度学习模型有可能会在某些较难识别的类别上产生负向作用,因此,在单一深度学习模型的选择上应尽可能地选择多样性的高性能模型。

(3)本研究中集成学习模块集成了不同的深度学习模型在相同的光谱特征下的分类结果,有研究[36－37]证明植被指数和纹理特征的加入会进一步提升模型的分类性能。所以,未来的研究应进一步讨论同一深度学习模型集成不同的输入特征(如光谱特征、植被指数特征及物候特征)的分类结果。

5 结论

(1)本研究提出了一种基于集成和置信学习的半监督学习遥感作物分类框架 ECL－SSCF,ECL－SSCF 不需要预先确定的作物特征曲线函数或特定地区作物季节性的数学假设,为大尺度作物制图提供了一种自动化方法。该模型的优点在于:构建集成学习模块,对多个深度学习模型的分类结果进行相对众数投票,提升作物分类精度;利用置信学习伪标签提纯策略扩充训练样本集以减少模型过拟合,实现少量标签下的半监督学习作物分类。

(2)在枝江市和桓台县 2 个研究区的作物分类结果显示：加入置信学习策略后，ECL－SSCF 在 2 个研究区伪样本的总体精度分别提升 17.2 个百分点和 9.3 个百分点，超越单一深度学习模型如 LSTM、Conv1D、ConvLSTM 和 TempCNN；利用提纯的伪样本训练 4 种深度学习模型并集成分类结果，ECL－SSCF 在 2 个研究区的分类精度分别达到了 90.4% 和 86.3%，明显优于单个深度学习模型。

(3)进一步对 ECL－SSCF 生成的伪样本数量和质量对所有 5 种模型预测性能影响的评估表明，当样本数量达到标准样本集 30% 左右，噪声样本比例低于标准样本集 30% 时，ECL－SSCF 都表现出稳健的性能，这一发现提供了一个平衡样本数量和质量的量化参考，优化了模型的训练过程，对于实际应用中遥感图像的预处理和噪声抑制具有重要的指导意义。总的来说，集成学习和置信学习策略的结合使 ECL－SSCF 获得了高质量的样本和稳定的模型性能。

参 考 文 献

[1] AZZARI G, LOBELL D B. Landsat-based classification in the cloud: an opportunity for a paradigm shift in land cover monitoring [J]. Remote Sensing of Environment, 2017, 202: 64－74.

[2] ZHANG D, PAN Y, ZHANG J, et al. A generalized approach based on convolutional neural networks for large area cropland mapping at very high resolution[J]. Remote Sensing of Environment, 2020, 247: 111912.

[3] ZHONG L, HU L, ZHOU H. Deep learning based multi-temporal crop classification[J]. Remote Sensing of Environment, 2019, 221: 430－443.

[4] 赵红伟, 陈仲新, 刘佳. 深度学习方法在作物遥感分类中的应用和挑战[J]. 中国农业资源与区划, 2020, 41(2): 35－49.
ZHAO Hongwei, CHEN Zhongxin, LIU Jia. Deep learning for crop classification of remote sensing data: applications and challenges[J]. Chinese Journal of Agricultural Resources and Regional Planning, 2020, 41(2): 35－49. (in Chinese)

[5] 陈理, 韩毅, 杨广, 等. 基于改进半监督模型的空间异质性农田特征提取研究[J]. 农业机械学报, 2023, 54(12): 173－185.
CHEN Li, HAN Yi, YANG Guang, et al. Spatially heterogeneous cropland characteristic extraction based on improved semi-supervised models[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(12): 173－185. (in Chinese)

[6] HAN Y, WEI C, ZHOU R, et al. Combining 3D－CNN and squeeze-and-excitation networks for remote sensing sea ice image classification[J]. Mathematical Problems in Engineering, 2020, 2020: 1－15.

[7] WANG L, LIU Y, DI H, et al. Semi-supervised dual relation learning for multi-label classification[J]. IEEE Transactions on Image Processing, 2021, 30: 9125－9135.

[8] JOZDANI S, CHEN D, CHEN W, et al. Leveraging deep neural networks to map caribou lichen in high-resolution satellite images based on a small-scale, noisy UAV-derived map[J]. Remote Sensing, 2021, 13(14): 2658.

[9] KWAK G-H, PARK N-W. Unsupervised domain adaptation with adversarial self-training for crop classification using remote sensing images[J]. Remote Sensing, 2022, 14(18): 4639.

[10] WANG Y, FENG L, ZHANG Z, et al. An unsupervised domain adaptation deep learning method for spatial and temporal transferable crop type mapping using Sentinel－2 imagery[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2023, 199: 102－117.

[11] 刘世晶, 刘阳春, 钱程, 等. 基于 CycleGAN 和注意力增强迁移学习的小样本鱼类识别[J]. 农业机械学报, 2023, 54(增刊): 296－302.
LIU Shijing, LIU Yangchun, QIAN Cheng, et al. Recognition of small sample cultured fish based on CycleGAN and attention enhanced transfer learning[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(Supp.): 296－302. (in Chinese)

[12] GARZA S E, SCHAEFFER S E. Community detection with the label propagation algorithm: a survey[J]. Physica A: Statistical Mechanics and its Applications, 2019, 534: 122058.

[13] HONG D, YOKOYA N, XIA G-S, et al. X-ModalNet: a semi-supervised deep cross-modal network for classification of remote sensing data[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2020, 167: 12－23.

[14] FANG Z, YANG Y, LI Z, et al. confident learning-based domain adaptation for hyperspectral image classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 1－16.

[15] 杨星, 方乐缘, 岳俊. 高光谱遥感影像半监督分类研究进展[J]. 遥感学报, 2024, 28(1): 20－41.
YANG Xing, FANG Leyuan, YUE Jun, et al. Advances in semi-supervised classification of hyperspectral remote sensing images[J]. National Remote Sensing Bulletin, 2024, 28(1): 20－41. (in Chinese)

[16] 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.

[17] 陈诗扬, 刘佳. 基于 GF－6 时序数据的农作物识别深度学习算法评估[J]. 农业工程学报, 2021, 37(15): 161－168.

CHEN Shiyang, LIU Jia. Evaluation of deep learning algorithm for crop identification based on GF-6 time series images[J]. Transactions of the CSAE, 2021, 37(15):161-168. (in Chinese)

[18] KUSSUL N, LAVRENIUK M, SKAKUN S, et al. Deep learning classification of land cover and crop types using remote sensing data[J]. IEEE Geoscience Remote Sensing Letters, 2017, 14: 778-782.

[19] SAINI R, GHOSH S K. Ensemble classifiers in remote sensing: a review[C]//2017 International Conference on Computing, Communication and Automation (ICCCA), 2017:1148-1152.

[20] UHL F, GRAESDAL RASMUSSEN T, OPPELT N. Classification ensembles for beach cast and drifting vegetation mapping with Sentinel-2 and PlanetScope[J]. Geosciences, 2022, 12(1): 15.

[21] TURKOGLU M O, ARONCO S D, WEGNER J D, et al. Gating revisited: deep multi-layer RNNs that can be trained[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2022, 44(8): 4081-4092.

[22] SZEGEDY C, WEI L, YANGQING J, et al. Going deeper with convolutions[C]//2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2015:1-9.

[23] PELLETIER C, WEBB G I, PETITJEAN F, et al. Temporal convolutional neural network for the classification of satellite image time series[J]. Remote Sensing, 2019, 11(5):523.

[24] SHI X, CHEN Z, WANG H, et al. Convolutional LSTM network: a machine learning approach for precipitation nowcasting [J]. Advances in Neural Information Processing Systems, 2015, 28: 6352419.

[25] AFRASIYABI A, LAROCHELLE H, LALONDE J F, et al. Matching feature sets for few-shot image classification[C]//2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR) Published, 2022: 9004-9014.

[26] LÓPEZ-SERRANO P M, LÓPEZ-SÁNCHEZ C A, ÁLVAREZ-GONZÁLEZ J G, et al. A comparison of machine learning techniques applied to Landsat-5 TM spectral data for biomass estimation[J]. Canadian Journal of Remote Sensing, 2016, 42(6): 690-705.

[27] THANH NOI P, KAPPAS M. Comparison of random forest, k-nearest neighbor, and support vector machine classifiers for land cover classification using Sentinel-2 imagery[J]. Sensors, 2018, 18(1): 18.

[28] NORTHCUTT C G, JIANG L, CHUANG I L. Confident learning: estimating uncertainty in dataset labels[J]. Journal of Artificial Intelligence Research, 2019, 70: 1373-1411.

[29] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection[C]//2017 IEEE International Conference on Computer Vision (ICCV), 2017: 2999-3007.

[30] DOU P, SHEN H, LI Z, et al. Time series remote sensing image classification framework using combination of deep learning and multiple classifiers system[J]. International Journal of Applied Earth Observation and Geoinformation, 2021, 103: 102477.

[31] CONGALTON R G. A review of assessing the accuracy of classification of remotely sensed data[J]. Remote Sensing of Environment, 1991, 37(1): 35-46.

[32] JIANG Z, ZHAO L, LU Y, et al. A semi-supervised resampling method for class-imbalanced learning[J]. Expert Systems with Applications, 2023, 221:119733.

[33] 胡帅, 高峰, 龚卓然, 等. 基于 Transformer 和通道混合并行卷积的高光谱图像去噪[J]. 中国图象图形学报, 2024, 29(7): 2063-2074.
HU Shuai, GAO Feng, GONG Zhuoran, et al. Parallel channel shuffling and Transformer-based denoising for hyperspectral images[J]. Journal of Image and Graphics, 2024, 29(7):2063-2074. (in Chinese)

[34] LUO X, SUN J, WANG L, et al. Short-term wind speed forecasting via stacked extreme learning machine with generalized correntropy[J]. IEEE Transactions on Industrial Informatics, 2018, 14(11): 4963-4971.

[35] MA Z, DAI Q. Selected a stacking ELMs for time series prediction[J]. Neural Processing Letters, 2016, 44(3): 831-856.

[36] MA Z, LI W, WARNER T A, et al. A framework combined stacking ensemble algorithm to classify crop in complex agricultural landscape of high altitude regions with Gaofen-6 imagery and elevation data[J]. International Journal of Applied Earth Observation and Geoinformation, 2023, 122: 103386.

[37] 靳宁, 孙林, 张东彦, 等. 基于 CBAM-U-HRNet 模型和 Sentinel-2 数据的棉花种植地块提取[J]. 农业机械学报, 2023, 54(11): 159-168.
JIN Ning, SUN Lin, ZHANG Dongyan, et al. Classification of cotton planting area using CBAM-U-HRNet model and Sentinel 2 data[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(11): 159-168. (in Chinese)