

# 基于集成对比学习的高分辨遥感图像搜索模型

顾程成<sup>1</sup>, 孙 勇<sup>1,2</sup>, 程千禧<sup>3</sup>, 谭文安<sup>1</sup>

(1.上海第二工业大学计算机与信息工程学院, 上海 201209)

(2.滁州学院实景地理环境安徽省重点实验室, 安徽 滁州 239000)

(3.安徽大学资源环境学院, 安徽 合肥 230009)

**[摘要]** 为解决单一对比学习模型只关注图像的局部特征问题, 提出一种基于集成对比学习的高分辨率遥感图像搜索模型. 首先, 采用动量更新无监督视觉表示学习与采样最近邻对比学习模型分别提取遥感图像的局部和全局特征, 以学习出更好的遥感图像视觉表征. 在此基础上, 提出面向高分辨率遥感图像表征的集成对比学习模型, 根据其在遥感图像分类任务的表现, 对不同的对比学习器自适应地赋予不同的集成权重, 通过统计对比学习特征预测准确率, 进一步优化对比学习器的学习速度. 最后, 将集成对比学习模型运用于高分辨率遥感图像搜索. 在 EuroSat、UCmerced、WHU-RS19、PatternNet 等公开遥感图像数据集上的实验结果表明, 所提出的模型在图像搜索任务中相较传统的对比方法有较稳定的准确率提升.

**[关键词]** 对比学习, 集成学习, 最近邻对比学习, 动量更新对比学习, 遥感图像搜索

**[中图分类号]** TP751; TP18 **[文献标志码]** A **[文章编号]** 1672-1292(2025)01-0022-08

## Hi-Res Remote Image Searching Based on Ensemble Contrastive Learning

Gu Chengcheng<sup>1</sup>, Sun Yong<sup>1,2</sup>, Cheng Qianxi<sup>3</sup>, Tan Wenan<sup>1</sup>

(1.School of Computer and Information Engineering, Shanghai Polytechnic University, Shanghai 201209, China)

(2.Key Laboratory of Physical Geographic Environment of Anhui Province, Chuzhou University, Chuzhou 239000, China)

(3.School of Resources and Environmental Engineering, Anhui University, Hefei 230009, China)

**Abstract:** To address the issue of currently many single contrastive learning models focusing only on local features of images, a new high resolution remote image searching model based on ensemble contrastive learning is proposed. Firstly, local and global features are learned from remote images by momentum contrastive learning and nearest neighbor contrastive learning methods. Secondly, on this basis, high resolution remote image searching model based on ensemble contrastive learning is proposed, which sets different weights for different contrastive learners according to their own performance in downstream classification tasks, and then further optimizes the learning speeds of learners with the accuracy of contrastive learning features. Finally, ensemble contrastive learning model is applied in Hi-Res remote image searching. Experiments are conducted by using public remote sensing image datasets including EuroSat, UCmerced, WHU-RS19, and PatternNet. The results indicate that the proposed model demonstrates a more stable improvement in accuracy compared with traditional contrastive methods for image searching tasks.

**Key words:** contrastive learning, ensemble learning, nearest-neighbor contrastive learning, momentum contrastive learning, remote image search

传统的基于关键字内容的遥感图像检索技术通过提取图像的纹理、颜色和形状等底层特征进行检索, 但底层特征难以反映高层的语义信息, 容易形成较大的语义鸿沟<sup>[1]</sup>, 且依赖人为地提取相关特征. 高分辨率的遥感图像内容复杂、细节信息丰富, 浅层特征不能准确描述遥感图像语义特征. 目前解决遥感图像搜索问题的主流方法为人工智能深度学习, 深度自监督学习特别是对比学习技术的进步给高分辨率遥感图像搜索相关领域研究的智能化发展及融合创新带来了新的机遇<sup>[2-3]</sup>. 近几年来对比学习一直在不断发展, 对比学习的类型也逐渐丰富.

收稿日期: 2024-04-28.

基金项目: 安徽省教育厅重大重点科学研究项目(2022AH051113)、安徽省重点实验室开放基金资助项目(2022PGE003)、滁州学院科学研究基金重点项目(2022XJZD06).

通讯作者: 孙勇, 博士, 副教授, 研究方向: 协同计算与地理空间人工智能. E-mail: ysun.nuaa@foxmail.com

很多单一对比模型只关注局部特征,忽略了高分辨率图像丰富的细节可能导致的过拟合问题. 集成学习方法结合多个模型的决策来提高整体性能,能将多个弱学习器结合以获得更好的训练结果. 目前有关对比学习和集成学习结合使用的研究相对较少.

## 1 相关工作

对比学习<sup>[4-6]</sup>核心思路为通过比较样本之间的相似性和差异性,令样本与正样本尽可能相近,而与负样本尽可能远离. 在此基础上,Grill 等<sup>[7]</sup>提出无显性负样本的对比学习方法;Chen 等<sup>[8]</sup>建立了简洁的对比学习框架用于获取图像特征,且采用数据增强、大批量样本等方法提高对比学习模型的学习性能.

集成学习方法是指把多个给定学习算法构建的基估计器的预测结果结合起来,从而获得相比单个估计器预测更好的泛化能力和鲁棒性. 本文将以 AdaBoost<sup>[9]</sup>作为主要的集成学习技术进行讨论. AdaBoost 是一种将多个弱分类器级联在一起形成强分类器来定位特定目标的算法,通过加权组合几种弱学习器,同时采用自适应学习策略,其集成效果优秀,缺点是对噪声较为敏感.

目前,自监督学习方法在遥感图像上的应用较为广泛. 周登文等<sup>[10]</sup>尝试使用逐像素对比方法解决高分辨率图像失真、细节丢失等问题;Li 等<sup>[11]</sup>自创 GLC 网络,运用对比学习方法同时学习高分辨率遥感图像的全局特征与局部特征,且尝试在上游任务与下游任务中分别使用不同的数据集,取得了较优的效果;Zhang 等<sup>[12]</sup>基于集成学习方法,学习非线性相关性数据的特性,应用于遥感图像中;牟卿志等<sup>[13]</sup>使用神经网络搭建的集成学习框架评估不同质量的图像;Biswas 等<sup>[14]</sup>构建了 pNNCLR 模型,使用平滑权重更新及随机采样方法在最近邻附近采样,优化了 NNCLR<sup>[4]</sup>依赖支持集质量的不稳定的缺点,相较原 NNCLR 有较大提升;Lebailly 等<sup>[15]</sup>验证了直接将自举和自蒸馏结合导致性能下降,并提出了一种基于自蒸馏的表示学习方法,根据潜在空间质量的估计,自适应地使用最近邻算法,在标准下游任务中有优秀的表现;Ge 等<sup>[16]</sup>提出 SNCLR,是一种典型的使用二进制标记方案的对比学习方法,引入了“软邻居”的概念,即与当前样本高度相关,但属于不同类别的实例,通过交叉注意力模块量化实例与软邻居间的相关性,对编码器特征的表示有极大改善.

目前研究者在自监督学习领域已有较深的挖掘,但与集成对比学习相关的研究依然极少, Mienye 等<sup>[17]</sup>对现有集成方法的算法总结中尚未有采取将对比学习方法作为集成中的学习器的方法,因此导致各类方法对于遥感图像的特征学习较为单一,较难做到兼顾学习全局特征及局部特征,导致训练效果不稳定,在不同训练集上效果差距较大.

本文基于以上研究现状,提出一种基于集成对比学习的高分辨率遥感图像搜索模型,旨在解决遥感图像搜索问题. 首先采用动量更新无监督视觉表示学习模型与采样最近邻对比学习模型分别提取遥感图像的局部特征和全局特征,择优改进,提升效率,以获得更好的遥感图像视觉表征;其次整合集成学习与对比学习,研究如何高效集成并发挥其中各个对比学习学习器的优势以提升搜索效率;最后构建一个能够处理和识别高分辨率遥感图像的搜索模型,通过反复优化与训练使其能够准确快速地检索出与查询图像相似的遥感图像.

## 2 自适应集成对比学习模型

### 2.1 基于对比学习模型的高分辨率遥感图像特征提取

本文的自适应集成学习算法的基础为对比自监督学习模型. 为优化对比学习模型,提升其在高分辨率遥感图像搜索中的表现,在模型训练部分采取迁移学习方法,利用已有的预训练模型作为基础,通过微调使模型适应遥感图像搜索的特定任务以加速模型的训练过程,提高模型的泛化能力;同时为模型设计特定的下游任务,例如图像分类,以进一步增强模型对遥感图像特征的理解和处理能力. 由于动量更新方式的无监督视觉表示学习可有效提取局部特征,采样最近邻对比学习模型可提取全局特征,因此,将采样最近邻对比学习与动量更新方式对比学习进行自适应集成,将兼顾融合局部特征与全局特征的优势运用于高分辨率遥感图像搜索.

#### 2.1.1 基于采样最近邻对比学习的遥感图像全局特征提取

本文采用最近邻对比算法提取全局特征,并根据下游任务优化损失函数更新. 遥感图像数据集在随机数据增广后的样本嵌入  $z_i$  与编码后进行下游任务,并搜索支持集中的最近邻样本  $Q$  作为正样本,与第

二种增广样本嵌入  $z_i$  作比较产生 InfoNCE 损失<sup>[18]</sup>,同时将下游分类任务的结果反馈更新至支持集及损失函数以进一步优化学习效果及提高学习效率. 其损失函数定义为:

$$\mathcal{L}_i^{\text{NNCLR}} = -\log \frac{\exp(\text{NN}(z_i, Q) \cdot z_i^+ / \tau) + \begin{cases} \frac{\alpha n}{\tau(n+i)} & (\text{if correct}) \\ \frac{\alpha(n+i)}{n\tau} & (\text{if incorrect}) \end{cases}}{\sum_{k=1}^n \exp(\text{NN}(z_i, Q) \cdot z_k^+ / \tau)}, \quad (1)$$

式中, NN 为最近邻查找算法:

$$\text{NN}(z, Q) = \arg \min_{q \in Q} \|z - q\|_2. \quad (2)$$

采样最近邻对比学习方法旨在将相似的样本映射到接近的点,采用支持集用于存储近邻正样本与另一视图对比,在每次训练中加入新的正样本以更新支持集并更新损失函数,如此循环直至完成训练任务. 以最近邻对比学习方法采用对比网络用于生成负样本对,样本同时与增广正样本及支持集最近邻样本对比,使得采样最近邻对比学习方法的特征提取过程更加综合,有利于捕捉整体图像的特征,使得其在提取全局特征时表现优异.

### 2.1.2 基于动量更新对比学习的遥感图像局部特征提取

本文采用动量更新对比算法以提高模型的局部特征提取能力. 首先构建动态字典,采用对比损失、实例判别预文本任务和动量更新来训练模型,以动态编码器更新策略,鼓励模型关注数据中的细粒度的细节和局部特征. 其次,采取多次裁剪 (Multi-crop) 的数据集增广方法,在训练过程中构建大量的较小尺寸的正样本及负样本,使得局部特征的动量更新视觉表征方法更擅长提取遥感图像局部特征. 局部特征的动量更新视觉表征模型基于端对端对比学习和内存库做出改进,与最近邻对比方法同样使用 InfoNCE 损失:

$$\mathcal{L}_q^{\text{Moco}} = -\log \frac{\exp(q \cdot k_+ / \tau)}{\sum_{i=0}^K \exp(q \cdot k_i / \tau)}. \quad (3)$$

此外,使用类似 EMA 算法的动量更新方法来更新 backbone 参数:

$$\theta_k \leftarrow m\theta_k + (1-m)\theta_q. \quad (4)$$

借鉴 SimCLR 使用两层的多层感知机代替全连接层,本文的局部特征的动量更新视觉表征方法增加了高斯模糊、随机裁剪、图像转置等数据增强方法,同时基于 Transformer 作出改进,使用 ViT 代替动量更新并对其初始化过程进行优化,提升了训练效果.

## 2.2 高分辨率遥感图像表征的自适应集成对比学习

由于现有集成学习和对比学习相结合的研究极少,本文采用神经网络设计的研究方法,自主设计神经网络架构,配置神经网络,选择激活函数,创新连接方式,旨在构建能够有效处理高分辨率遥感图像并执行精确搜索任务的模型,以实现高效的特征融合,确保来自不同模型的特征能够被有效整合,帮助集成对比学习模型提取有效特征,从而提升搜索性能. 此外,使用优化算法指导模型更好地学习图像之间的相似性和差异性,从而提高搜索任务的准确性. 如图 1 所示,本文使用 AdaBoost 自适应集成对比方法学习器,依

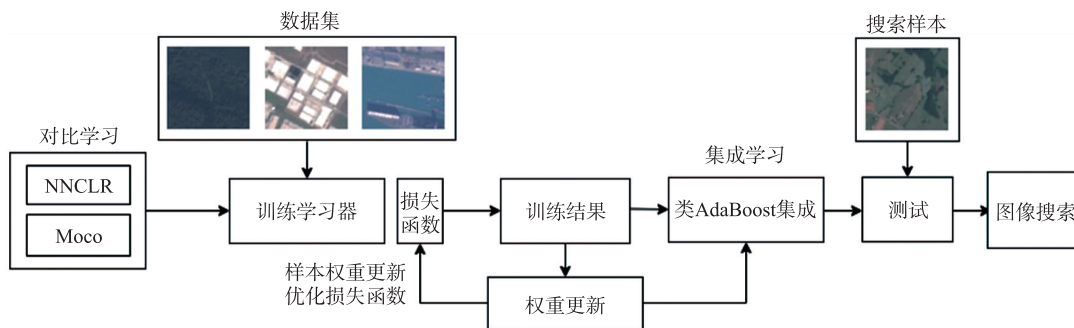


图 1 集成对比方法实现

Fig. 1 Implementation of ensemble contrastive method

据训练表现不断更新学习器的权重,以提升模型的性能。

遥感图像训练集包含实例空间及标签信息. 学习器采用采样最近邻对比学习方法与局部特征的动量更新视觉表征方法分别通过下游分类任务更新训练,基于每个学习器在各个类别的训练效果调整样本权重及更新损失函数使其更注重学习较弱的遥感图像类别,训练后根据两者准确率更新权重. 在遥感图像搜索任务中,首先学习器作分类,根据每个学习器权重进行加权平均,在该分类下准确率较高的学习器的权重较高,以实现类 AdaBoost 集成方法. 具体训练步骤如算法 1 所示.

算法 1 模型训练步骤

1. Train process;
2. Function
3. While score<Train\_Target;
4. NNCLR\_Train(); Moco\_Train();
5. Calculation:  $a_t = \frac{1}{2} \ln \left( \frac{1 - \varepsilon_t}{\varepsilon_t} \right)$
6.  $D_{t+1}(i) = \frac{D_t(i) e^{-a_t y_i h_t(x_i)}}{\text{Sum}(D)}$
7.  $w_t^{\text{nnclr}} = \frac{e^{\alpha \cdot D_t^{\text{nnclr}}}}{e^{\alpha \cdot D_t^{\text{nnclr}}} + e^{\alpha \cdot D_t^{\text{moco}}}}, w_t^{\text{moco}} = \frac{e^{\alpha \cdot D_t^{\text{moco}}}}{e^{\alpha \cdot D_t^{\text{nnclr}}} + e^{\alpha \cdot D_t^{\text{moco}}}}$
8. End Train

其中,每个学习器的错误率计算方法为:

$$\varepsilon_t = \Pr_{i \sim \omega_t} [P_t(x_i) \neq y_i] = \sum_{i: P_t(x_i) \neq y_i} \omega_t(i).$$

在算法 1 中, score 为学习器准确率得分;  $t$  为样本分类类别;  $D$  为分类权重;  $\omega$  为学习器权重;  $\varepsilon$  为错误率;  $\alpha$  为学习率参数.

### 3 实验结果与分析

本文在数类遥感图像进行实验以评估集成对比方法在遥感图像搜索任务中的表现. 为证明其有效性,将最新模型与本文所提出的自适应集成对比方法进行比较. 最后进行消融实验,通过实验分析部分超参数以及对对比学习方法选择对模型的影响.

#### 3.1 实验细节

##### 3.1.1 评价指标

核心评价指标为模型在下游图像分类任务的宏平均  $F1$  分数<sup>[19]</sup>. 宏平均  $F1$  分数为综合考虑准确率和召回率的指标,该指标计算每个类别的  $F1$  分数,取其平均值,以确保每个类别对评估指标的贡献相等. 该指标可为图像数量及图像类别数各有差异的图像数据集提供较为公平的衡量标准,其计算公式为:

$$\text{Macro-F1} = \frac{1}{K} \sum_{i=1}^K F1_i, \quad (5)$$

$$F1 = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}, \quad (6)$$

式中,  $K$  为总类别数; Precision 为准确率; Recall 为召回率.

##### 3.1.2 实验设置

本实验基于 Pytorch 的深度学习框架,在实验训练阶段使用 Resnet-50 作为编码器网络,同时映射网络使用一层线性网络,分类器或搜索器为一层全连接网络. 在图像增广方面采用了自动增广方法,学习率设置为 0.01,训练批次大小始终设置为 256,训练次数设置为 100 次. 其中,式(1)中的  $i$  与算法 1 中的  $\alpha$  均为可调的超参数,在本实验中取  $i$  为 0.01,  $\alpha$  为 0.5. 图像集采用 EuroSat<sup>[20]</sup>、UCmerced、WHU-RS19、PatternNet<sup>[21]</sup>等多种公开高分辨率遥感数据集,详细数据如表 1 所示.

3.2 遥感图像分类下游任务

对 NNCLR<sup>[4]</sup> 和 Moco<sup>[5]</sup> 分别单独进行模型训练并分别完成分类任务,设置宏平均  $F1$  分数为模型表现的评价指标. 表 2 展示了单独的对比学习方法 NNCLR、Moco 及本文所提出面向高分辨率遥感图像表征的集成对比学习算法 (EnsembleCL) 在 EuroSat、UCmerced、WHU-RS19、PatternNet 数据集上的宏平均  $F1$  分数. 可以发现,模型的表现受数据集类别数量影响较大,对于具有 38 种场景类别的 PatternNet 数据集表现稍逊,而其他数据集表现较为平衡,可初步推断 EnsembleCL 模型受数据集的分辨率高低和数量影响较小,因此适合完成高分辨率图像任务. 此外,EnsembleCL 方法相比 NNCLR 与 Moco 两种单独的对比方法有较明显的提升,验证了集成对比学习方法的可行性.

表 1 各遥感图像数据集数据					表 2 图像分类任务结果				
Table 1 Datasets of remote sensing images					Table 2 Results in image classification				
数据集	类别数	类别图像数	图像总数	图像像素	方法	EuroSat	UCmerced	WHU-RS19	PatternNet
EuroSat	10	2 000~3 000	27 000	64×64	NNCLR	86.86	83.26	86.92	80.46
UCmerced	21	100	2 100	256×256	Moco	85.02	83.66	84.98	81.13
WHU-RS19	19	<50	1 005	600×600	EnsembleCL	90.54	89.68	89.12	88.13
PatternNet	38	800	30 400	256×256					

3.3 遥感图像搜索任务

本文使用宏平均  $F1$  分数评估集成对比方法在遥感图像搜索任务中的表现,实验结果基于学习器完成图像分类下游任务后的验证测试. 与遥感图像分类任务相同,本文所提出的 EnsembleCL 方法的表现优于单独的 NNCLR 与 Moco 算法. 如表 3 所示,将 EnsembleCL 方法与 NNCLR、Moco 及近年的新模型 AdaSim、pNNCLR 作比较,在 Resnet-50 网络基础上完成各个数据集的搜索任务. 从结果上看,EnsembleCL 整体略优于 pNNCLR 与 AdaSim. EnsembleCL 在各个数据集上均有不错的效果,表现稳定;pNNCLR 与 AdaSim 方差较大,AdaSim 在 PatternNet 数据集上效果落后于其他数据集.

表 3 图像搜索任务结果				
Table 3 Results in image search				
方法	EuroSat	UCmerced	WHU-RS19	PatternNet
NNCLR <sup>[4]</sup>	87.54	85.38	88.11	86.65
Moco <sup>[5]</sup>	87.07	87.40	87.78	88.59
pNNCLR <sup>[14]</sup>	92.56	91.33	90.06	88.51
AdaSim <sup>[15]</sup>	87.35	91.20	91.35	86.67
EnsembleCL	92.87	92.79	91.87	91.11

在遥感图像搜索任务中,不同类别的图像表现存在一定的差异性,大部分图像类别达到优秀的表现数值. Eurosat 中有 5 种图像类别、Ucmerced 中有 10 种图像类别、WHU-RS19 中有 5 种图像类别、PatternNet 中有 13 种图像类别均达到了 95% 的  $F1$  分数,仅有少数图像类别如 PermanentCrop、Dense Residential 及 Football field 表现较差,可能是由于上述类别图像集包含图像色彩结构更复杂且较易与其他类别图像混淆. 值得注意的是 PatternNet 数据集为其中类别最丰富、图像分辨率最高的数据集,其综合表现仍较优,在一定程度上证明 EnsembleCL 方法对于较有挑战性的高分辨率图像搜索仍保持很强的有效性.

为进一步挖掘本文算法的性能、更直观地体现图像各类别的精确率与召回率等表现,选择类别最丰富与分辨率最高的 PatternNet 生成混淆矩阵,如图 2 所示. 图中,首列与末行的序号对应 PatternNet 中类别的字母升序排列. 由图可知,10 种类别精准度高于 95%,仅 2 种类别低于 80% 精准度,该图像搜索表现达到较为优秀的水准. 图中类内图像差异较大,识别难度较高的类别,如 BasketballCourt、CoastalMansion、SparseResidential、TransformerStation 依然达到了较高的精确率. 此外,对于类间相似度较高的类别,如 Runway、RunwayMarking 及 Parking Lot、Parking Space 等,模型依然保持较低的混淆率,一定程度上证明该模型对于图像细节的学习能力.

3.4 消融实验

为分析集成对比模型各部分对于模型性能的影响,设置了不同超参数进行消融实验,如图 3 所示,其中,横轴为不同图像数据集,纵轴为宏平均  $F1$  分数,不同颜色折线为不同参数数据,红色为默认参数. 由

该数据可以发现,  $i=0$  即在未根据下游任务表现优化损失函数的情况, 其表现略逊于默认参数值, 在  $i=0.001$  下影响较小, 相比而言  $i=0.01$  下表现最优. 同样  $\alpha=0.5$  时模型整体表现最为平衡, 优于其他取值. 因此本实验最终确定使用这两种超参数.

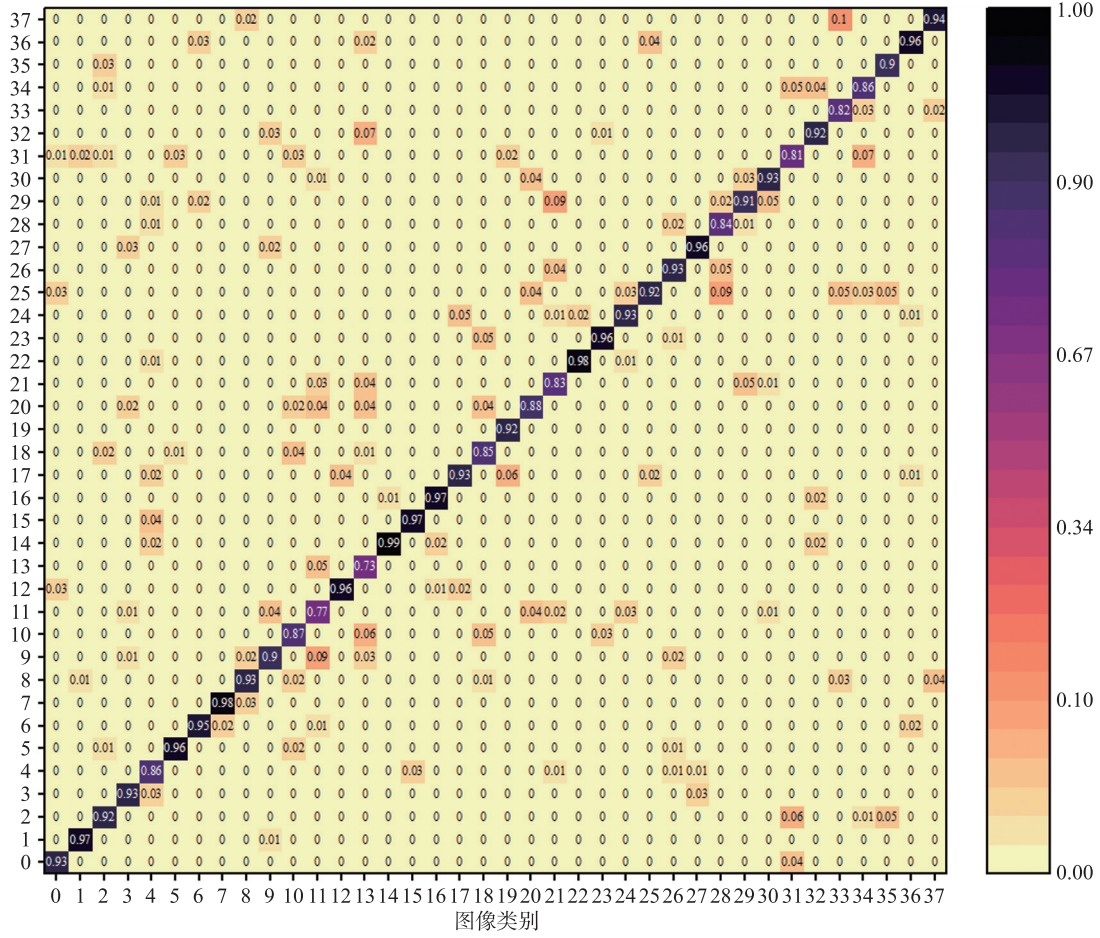


图2 PatternNet数据集混淆矩阵

Fig. 2 PatternNet confusion matrix

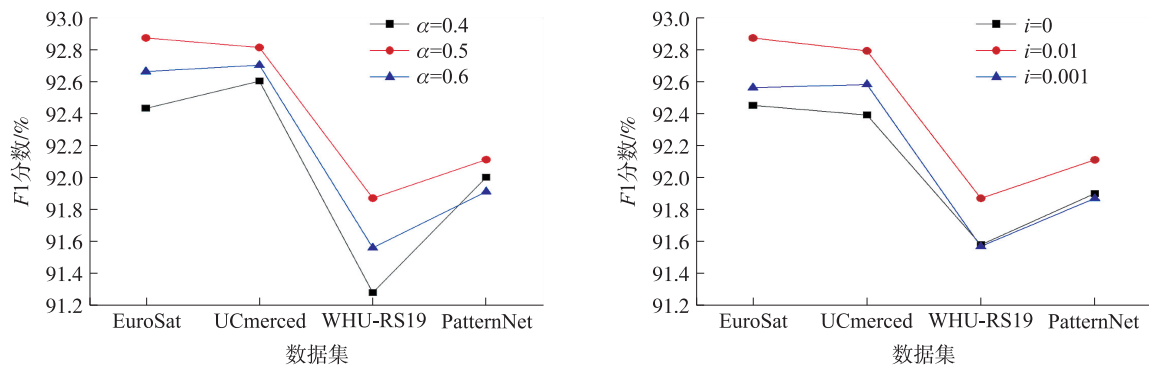


图3 超参数消融实验结果

Fig. 3 Hyperparametric ablation experiment results

为分析不同对比方法对模型性能的影响,选择不同对比方法进行消融实验. 选择 BYOL、SimCLR、NNCLR、Moco 4 种对比方法分别单独完成图像搜索任务,再将各对比学习方法两两组合进行运算,结果如表 4 所示,验证了集成对比学习的可行性. 在所有对比方法组合中,EnsembleCL 数据上最优,可判断 NNCLR 学习全局特征与 Moco 学习局部特征对于模型表现有明显提升,该两种对比学习方法均着眼于对比学习框架,旨在通过建模正样本对和负样本对之间的相似性来学习视觉表示,在集成过程中有更佳的兼容性. 而在其他对比学习方法组合中,BYOL 与 SimCLR 组合有仅次于 EnsembleCL 的优秀表现,推测 BYOL 与 SimCLR 均最大化正样本对之间的相似性,因此在集成过程中亦有不错的表现.

4 结论

本文面向高分辨率遥感图像搜索任务,提出了一种自适应集成对比学习方法,探索并分析了目前的深度学习方法在遥感图像搜索中的应用,发现现有的对比学习方法在全面学习图像表示上仍有优化空间,基于此引入了集成对比学习模型. 通过两种对比学习方法的集成效果互补,全面学习图像的局部特征及全局特征,进一步提高了模型的特征学习能力. 同时优化对比方法训练速度,增加基于图像分类任务对损失函数的更新,提高了模型训练效率,为模型学习提供了新的类别特征. 为证实以上结论的可靠性,进行了对比和消融实验,证明本文所提出的方法相较单一对比学习方法有较明显的提升. 由于遥感图像数量庞大,类别众多,也可能存在更复杂的任务,未来的工作可基于集成对比学习方法对于遥感图像相关任务作更深入的探索.

[ 参考文献 ] (References)

[ 1 ] 张重生,陈杰,李岐龙,等. 深度对比学习综述[J]. 自动化学报,2023,49(1):15-39.

[ 2 ] 黄界生. 基于深度学习的计算机视觉中图像检索算法研究[J]. 信息技术与信息化,2022(9):181-184.

[ 3 ] 朱鹏飞,张琬迎,王煜,等. 考虑多粒度类相关性的对比式开放集识别方法[J]. 软件学报,2022,33(4):1156-1169.

[ 4 ] DWIBEDI D,AYTAR Y,TOMPSON J,et al. With a little help from my friends:Nearest-neighbor contrastive learning of visual representations[C]//Proceedings of the 2021 IEEE/CVF International Conference on Computer Vision (ICCV). Montreal, Canada:IEEE,2021.

[ 5 ] HE K M,FAN H Q,WU Y X,et al. Momentum contrast for unsupervised visual representation learning[C]//Proceedings of the 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle,USA:IEEE,2020.

[ 6 ] SCHIAPPA M C,RAWAT Y S,SHAH M. Self-supervised learning for videos:A survey[J]. ACM Computing Surveys,2023,55(13s):288.

[ 7 ] GRILL J B,STRUB F,ALTCHÉ F,et al. Bootstrap your own latent:A new approach to self-supervised learning[J]. Advances in Neural Information Processing Systems,2020,33:21271-21284.

[ 8 ] CHEN T,KORNBLITH S,NOROUZI M,et al. A simple framework for contrastive learning of visual representations[C]//Proceedings of the 37th International Conference on Machine Learning (ICML2020). Online:ICML,2020.

[ 9 ] 游文霞,申坤,杨楠,等. 基于 AdaBoost 集成学习的窃电检测研究[J]. 电力系统保护与控制,2020,48(19):151-159.

[ 10 ] 周登文,刘子涵,刘玉铠. 基于像素对比学习的图像超分辨率算法[J]. 自动化学报,2024,50(1):181-193.

[ 11 ] LI H F,LI Y,ZHANG G,et al. Global and local contrastive self-supervised learning for semantic segmentation of HR remote sensing images[J]. IEEE Transactions on Geoscience and Remote Sensing,2022,60:5618014.

[ 12 ] ZHANG Y Z,LIU J J,SHEN W J. A review of ensemble learning algorithms used in remote sensing applications[J]. Applied Sciences,2022,12(17):8654.

[ 13 ] 牟卿志,李玉婷,孙宗升,等. 集成学习算法在图像质量评估中的应用[J]. 智能计算机与应用,2023,13(10):147-150.

[ 14 ] BISWAS M,BUCKHASH H,PRASAD D K. pNNCLR: Stochastic pseudo neighborhoods for contrastive learning based

- unsupervised representation learning problems[J]. *Neurocomputing*, 2024, 593: 127810.
- [15] LEBAILLY T, STEGMÜLLER T, BOZORGTABAR B, et al. Adaptive similarity bootstrapping for self-distillation based representation learning[C]//*Proceedings of the 2023 IEEE/CVF International Conference on Computer Vision (ICCV)*. Paris, France: IEEE, 2023.
- [16] GE C J, WANG J L, TONG Z, et al. Soft neighbors are positive supporters in contrastive visual representation learning[EB/OL]. (2023-03-30) [2024-04-28]. <https://doi.org/10.48550/arXiv.2303.17142>.
- [17] MIENYE I D, SUN Y X. A survey of ensemble learning: Concepts, algorithms, applications, and prospects[J]. *IEEE Access*, 2022, 10: 99129–99149.
- [18] FAN D, YANG D, LI X, et al. Look globally and locally: Inter-intra contrastive learning from unlabeled videos[C]//*ICLR 2023 Workshop on Mathematical and Empirical Understanding of Foundation Models*. Kigali, Rwanda: ICLR, 2023.
- [19] POWERS D M W. Evaluation: From precision, recall and F-measure to ROC, informedness, markedness & correlation[J]. *Journal of Machine Learning Technology*, 2011, 2(1): 37–63.
- [20] HELBER P, BISCHKE B, DENGEL A, et al. EuroSAT: A novel dataset and deep learning benchmark for land use and land cover classification[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2019, 12(7): 2217–2226.
- [21] ZHOU W X, NEWSAM S, LI C M, et al. PatternNet: A benchmark dataset for performance evaluation of remote sensing image retrieval[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2018, 145: 197–209.

[责任编辑: 严海琳]