

基于主动学习与消息传递的遥感图像超像素分类算法

梁升达, 童恒建

(中国地质大学(武汉) 计算机学院, 湖北 武汉 430078)

摘要: 超像素是将属于图像上同一物品的像素先进行像素块聚类, 将图像处理任务由像素级转为对象级, 再对超像素进行有效分类, 从而大量减少遥感图像上像素级标注标签的成本。然而, 现有的分类模型仍需要大量标签信息。虽然传统主动学习算法能够减少标注需求, 但其分类精度仍有待提升, 且难以利用超像素在图像上的空间信息。因此, 提出一种新颖的主动学习算法, 专门用于超像素分类任务。该算法使用超像素分割结果作为数据样本, 通过建立超像素区域邻接图利用空间信息, 并在主动学习训练过程中结合超像素特征与查询策略所获得的信息增益, 在邻域中进行消息传播, 充分利用超像素的空间信息, 从而有效提升分类模型的性能。该算法在标注样本比例仅占3.82%~5.77%时, 总体分类准确率能高于基线1.9%~3.7%, 为遥感图像超像素分类提供了一种有效的解决方案, 特别适用于标注成本高昂或数据量庞大的实际应用场景。

关键词: 主动学习; 超像素; 图网络; 消息传递; 遥感图像

DOI: 10.11907/rjdlk.242010

扫描二维码阅读全文:



中图分类号: TP751.1

文献标识码: A

文章编号: 1672-7800(2026)002-0154-10

Remote Sensing Image Superpixels Classification Algorithm Based on Active Learning and Message Passing

LIANG Shengda, TONG Hengjian

(School of Computer Science, China University of Geosciences (Wuhan), Wuhan 430078, China)

Abstract: Superpixel is to cluster pixels belonging to the same object on the image first, and the task of image processing is converted from pixel level to object level. Effective superpixel classification can greatly reduce the cost of pixel-level labeling on remote sensing images. However, the existing classification models still require a large amount of label information. Although the traditional active learning algorithm can greatly reduce such label requirements, the accuracy of classification still needs to be improved, and it is difficult to use the spatial information of superpixels on the image. This paper proposes a novel active learning algorithm specifically for superpixel classification tasks. The algorithm uses superpixel segmentation results as data samples, uses spatial information to build superpixel region adjacency graph, and combines superpixel features with information gain obtained by query strategy in the active learning training process to propagate information in the neighborhood. It makes full use of the spatial information of superpixels and effectively improves the performance of the classification model. When the proportion of labeled samples is only 3.82%~5.77%, the overall classification accuracy can be 1.9%~3.7% higher than the baseline, which provides an effective solution for remote sensing image superpixel classification, especially suitable for practical application scenarios with high labeling cost or large amount of data.

Key Words: active learning; superpixel; graph network; message passing; remote sensing image

0 引言

近年来, 在自然地理和卫星遥感等领域, 利用大规模

遥感数据进行数据挖掘具有重要的科学意义, 尤其是在处理地质灾害预估, 如泥石流流^[1]、洪水^[2]等任务时, 更精准的遥感图像处理会避免更多的经济损失^[3-7]。此外, 由于遥感技术的不断发展, 遥感图片的空间分辨率、辐射分辨率、时

收稿日期: 2024-12-31

基金项目: 国家自然科学基金资助项目(U1803117)

作者简介: 梁升达(1999-), 男, 中国地质大学(武汉)计算机学院硕士研究生, 研究方向为遥感图像处理与分析; 童恒建(1970-), 男, 博士, 中国地质大学(武汉)计算机学院教授, 研究方向为遥感图像处理与分析。本文通讯作者: 童恒建。

间分辨率以及光谱分辨率会越来越高,导致现在卫星遥感图片中的一个场景可能就包含了数亿像素,标注成本巨大^[8]。

超像素分割算法作为一种经典的图像分割算法^[9-11],能够将原本以像素为单位进行处理和分析的任务,转换为以图像对象为单位进行处理和分析的任务^[12-14],在保留地物特征的同时大幅度降低下游任务的运算负担。同时,主动学习的提出极大地减少了所需的训练样本数量,分类模型在精简训练集的表现能够媲美大量数据。常见的主动学习模式包含基于数据池^[15]、基于生成式数据^[16]和基于数据流^[17]3种基本模式。在处理固定数据时,通常采用基于数据池的方法。在基于数据池的主动学习流程中,程序会根据查询策略,反复选取有价值的未标记样本供专家标注。这些标记后的样本与初始样本一起构成新的训练集。通过程序精心筛选,所得到的训练集具有高效性,且能够筛选重复样本,从而减少专家标注的工作量,以更少的标签成本获取更优的性能。

当前,主动学习已经被广泛应用于超像素分类中。Mantripragada等^[18]提出了一种基于主动学习的图像分类和变化检测的内聚算法,解决了缺乏标签数据的问题。Liu等^[19]提出了一种面向对象的监督分类方法,用于消除斑点噪声(Speckle Noise)的影响。该方法采用主动学习方法和随机森林(Random Forest, RF)分类器,可以提高Pol-SAR图像的分类性能。上述方法将主动学习视为一种降低标签数据依赖性的技术,主要侧重于主动学习与超像素分割的结合应用。

Su等^[20]提出了一种计算样本信息的主动学习方法,使用基于对象的特征来估计样本的信息量。该过程通过一个二分类的随机森林完成,用于高光谱的遥感图像分类。Ma等^[21]研究了面向地理对象图像分析中的混合对象对主动分类器的影响,提出了一种主动学习方法。其通过随机抽样获得一定比例的零信息熵对象作为主动学习的种子训练样本,非零信息熵对象作为主动学习的候选集,以获得最优训练样本。李煜^[22]提出了一种像素-亚像素-超像素级多特征联合的主动学习分类算法。其中,像素作为图像的原始光谱信息,亚像素反映了像素的光谱混合信息,超像素描述了图像中不规则地物的空间光谱信息,结合主动学习,提高算法分类精度的同时降低了训练样本的数量。以上方法均是探究超像素在遥感图像分析中能够提供的自身特征,主要侧重于主动学习中的超像素特征研究。

在较新的研究中,Tang等^[23]基于社区发现算法生成超像素-社区映射,在主动学习流程中添加了专家知识扩展这一模块,有效利用超像素空间信息与专家标记,提高了常规主动学习的准确率。该算法直接将超像素作为分类对象,从像素标记转为超像素标记,减少了专家标记成本的同时也利用了超像素的空间信息,并且不需要对分类

模型或查询策略进行改动,具有良好的可扩展性。

上述研究表明,超像素之间的空间信息只作为不变的特征,主动学习分类模型对空间信息的感知被限制在初始化阶段。虽然超像素分割将像素级的空间信息扩展到了对象级,但是一个物体仍可能被过分割成多个超像素。同一物体的相邻超像素对之间具有紧密关联性,而不同物体间的相邻超像素对则会对分类精度产生负面影响。

为了解决充分利用超像素空间信息的问题,本文受图神经网络中消息传递机制的启发,提出一种在超像素区域邻接图上进行消息传播的主动学习算法^[24-25]。该算法将信息增益与主动学习的训练过程相结合,提升了超像素分类的准确率。主要贡献如下:

(1)提出一种基于区域邻接图的主动学习分类模型。该模型将传统基于池的主动学习流程转为基于图的主动学习流程,使用消息传播机制,在整个数据池中进行半监督学习过程。通过不断训练,图上每个节点都可以获取更为理想的空间信息。

(2)针对消息传播机制,设计了评估相似度这一个传播权重。基于色差与分类模型的评估信息结合进行传播,进一步提高空间信息的利用率和分类的准确性。

1 本文算法

1.1 超像素分割

超像素形对超像素群的图结构建模效果有显著影响。超像素形越规整,所建立的图结构越稀疏;而规整的超像素形能够更有效地表达超像素的空间信息。因此,为了获得更规整的超像素,本文选取简单线性迭代聚类算法(Simple Linear Iterative Clustering, SLIC)生成超像素^[26]。SLIC算法不仅具有操作简单、符合边界、计算速度快的优势,其生成的超像素较为规整,大小差异较小,更适合用于图结构建模。对于图中某一像素 $p(x_p, y_p, I_p)$ 与超像素中心 $c_k(x_k, y_k, I_k)$ 之间,SLIC的计算公式如式(1)所示。

$$D(p, C_k) = \sqrt{\left(\frac{x_p - x_k}{S}\right)^2 + \left(\frac{y_p - y_k}{S}\right)^2 + \left(\frac{I_p - I_k}{\delta}\right)^2} \quad (1)$$

式中, (x_p, y_p) 与 I_p 分别为像素 p 的空间坐标与颜色信息; (x_k, y_k) 和 I_k 则是超像素中心 c_k 的空间坐标与颜色信息; S 是空间步长,用于控制像素位置差异的权值,也表示超像素中心的搜索范围半径; δ 表示颜色步长,是控制超像素内部颜色差异的权重。在本文算法中,为了生成过分割充分并且紧凑的超像素,特将 S 设置在20~35之间,而 δ 设置在20~40之间。

1.2 特征提取

在本文中,超像素的特征提取采用色彩信息与纹理信息2个常见的特征。基础颜色特征采用超像素的全局颜色直方图(Global Color Histogram, GCH)形式^[27]。这是一种反映超像素内部颜色分布和比例的特征,不受超像素尺

寸、形状等变换影响,具有稳定描述超像素颜色信息的特性。超像素颜色直方图 GCH 使用 m 维向量 $H(h_1, h_2, \dots, h_m)$ 进行表示,其含义是将所有色彩通道合并后划分为 m 个区间。本文设置 m 为 48,对于一个内部像素数量为 N 的超像素,统计其每个区间内的像素频率,每个区间频率计算公式,如式(2)所示。

$$h_i = \frac{\sum_{j=1}^N D_j}{N} \quad (2)$$

式中, j 表示超像素内部像素的下标。若超像素内部第 j 个像素通道值位于所在的区间 i 内,则 $D_j=1$, 否则 $D_j=0$ 。

对于纹理信息,本文使用的是灰度共生矩阵(Gray-Level Co-occurrence Matrix, GLCM)^[28]。这是一种描述图像纹理的方法。GLCM 的原理是为图像中的每对具有空间相邻关系的像素建立一个矩阵,矩阵中的每个元素 $P(i, j)$

表示在该超像素中,按角度和距离分隔的像素 i 与 j 这对像素对中,邻近像素值的共现频率。根据这个矩阵,可以提取出图像的多个纹理特征,本文使用的是描述纹理均匀度的角二阶矩(Angular Second Moment, ASM)与描述纹理复杂性的熵(Entropy),如式(3)–式(4)所示。

$$ASM = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} P(i, j)^2 \quad (3)$$

$$Entropy = - \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} P(i, j) \cdot \log(P(i, j)) \quad (4)$$

1.3 超像素图结构建模

本文算法基于超像素的空间邻域信息构建了超像素区域邻接图。其定义为在图像上以相邻超像素构建的无权无向图,可以在超像素分割阶段进行初始化,具体如图 1 所示。




Fig. 1 Superpixel and adjacency diagram

图 1 超像素与邻接示意图

图 1 展示了原始图片、超像素分割结果示意图和超像素区域邻接图。可以直观的看出,超像素区域邻接图是一个稀疏图结构,而稀疏图的性质则有效减少计算的时间与内存开销。

1.4 消息传递机制

消息传递是机器学习中处理图结构数据的经典过程,广义上分为“消息”与“聚合”2个部分。在各式各样的图神经网络训练中,“消息”是特征向量的方式存在,而“聚合”是使用各式各样的神经网络层。由于特征工程提取的特征是在对特征空间降维的基础上完成的,并且超像素区域邻接图是较为稀疏的结构,因此,基于此的图神经网络模型整体效果并不突出。本文提出了一种适用于主动学习中超像素的消息传递方式,具体以超像素自身特征以及上下文特征作为传递机制的“消息”进行传递,同时,“聚合”过程中综合考虑分类模型的评估信息,并结合超像素之间的色差信息和相似度信息。具体计算如公式(5)所示。

$$x_{context} = \frac{\sum_{i=1}^n \Delta E_i \cdot (x_{i, self} + x_{i, context})}{2n} \quad (5)$$

$$x = (x_{self}, x_{context})$$

式中,邻域信息 $x_{context}$ 是以当前节点为中心的所有 n 个

邻域节点进行带权叠加后取平均值,所使用的权值 ΔE 是评估相似度。为了区分上下文信息与特征工程提取出的信息,将原本的特征工程信息标记为 x_{self} ,在训练过程中不断变化的邻域信息标记为 $x_{context}$ 。

消息传递流程如图 2 所示,是单个节点在一轮主动学习过程中的信息传播流程。

由图 2 可知, A 节点是中心节点,消息传递是将邻接节点 B、C 和 D 的特征传递到 A 上。邻接节点的颜色和纹理特征对应超像素自身的特征,而超像素自身特征与超像素空间特征的维度相同,且两者在每个位置上的特征含义一致。因此,合成消息的方式是将这 2 个特征进行平均叠加。叠加后的总体特征维度为原来的二分之一。根据分类模型评估结果以及与中心节点 A 计算得出的评估相似度,对消息进行加权池化,得到节点 A 新的空间特征,用于下一轮分类模型学习和评估。

1.5 算法流程

在传统的基于数据池的主动学习模式中,分类模型在学习过程开始前仅拥有少量用于初始化的数据实例。分类模型初始化完成后,它将依据查询策略去评估池中所有未标记的实例,并确定是否要查询其标签。如果实例符合预先设定的选择标准,那么它就会成为候选查询实例,其




Fig. 2 Message passing schematic

图 2 消息传递示意图

标签会被查询到;否则,分类模型会从未被专家标注的数据池中选择另一个实例。在获得候选实例的标签后,该实例及其标签将被添加到标签数据集中。随后,在更新后的训练集上再次训练分类模型。这个过程会一直重复,直到达到某个预设的停止标准或分类模型用完查询次数为止。

本文改进的基于池的主动学习模式是在专家标记的

同时进行消息传播。这个消息传播在首次训练时仅是简单的叠加和平均周围的节点信息,但在后续是根据评估相似度进行加权叠加空间信息。随着训练的不断进行,节点能够感受到的空间信息变的更广也更准确,最终得出更好的分类结果。算法详细执行流程如图 3 所示。




Fig. 3 Flow chart of the algorithm

图 3 算法流程图

由图 3 可知,输入遥感图像后,首先进行超像素分割,随后根据超像素的空间关系构建超像素区域邻接图,并对每个超像素进行特征提取。在完成特征提取后,对每类地物随机选取一个超像素作为激活样本,并将激活样本加入已标注样本池,剩余超像素则归为未标注样本池。在首次训练前,超像素的空间信息通过使用周围节点的自身特征进行简单初始化。在完成分类模型训练后,若尚未达到查询总数,分类模型会对未标记样本池中所有超像素进行评估。根据查询策略,选择具有最高价值的未标记超像素进行专家标注,并在此过程中计算每对相邻超像素之间的评估相似度。这些评估相似度的计算结果随后用于消息传递模块。消息传递模块通过超像素区域邻接图更新所有样本的空间特征,用于下一轮的分类模型训练。当专家标

记的数量达到预设的查询总数时,算法终止。

1.6 评估相似度

同一地物因为光线、云雾和人文活动等因素,会存在阳面与暗面或被轻微遮挡等情况,而不同地物也可能出现相近的颜色,如阴影与屋顶等。因此,色差的计算或是单纯特征相似度的计算并不能很好的解决这个问题,而主动学习的分类模型在不断的评估过程中会提高自身的泛化能力,拥有非线性的评估得分。本文提出一种评估相似度计算的方式,基于色差计算公式和特征相似度计算公式,评估增益项得到评估相似度。

1.6.1 色差项

欧拉距离是最简单的计算色差的方式,但是这种计算方法得出的差异与人眼观察到的差异程度并不相符。

CIE2000在CIE94基础上进行改进,是目前理论上较为优秀的色差计算方法。因此,本文算法中评估相似度时的色差项是基于CIE2000在超像素上的计算结果。假设2个超

像素平均lab的通道值分别为 $c_1(L_1^*, a_1^*, b_1^*)$ 和 $c_2(L_2^*, a_2^*, b_2^*)$,则色差项 $\Delta E_{\text{色差}}$ 计算公式如式(6)所示。

$$\Delta E_{\text{CIE2000}} = \sqrt{\left(\frac{\Delta L'}{K_L S_L}\right)^2 + \left(\frac{\Delta C'_{ab}}{K_C S_C}\right)^2 + \left(\frac{\Delta H'_{ab}}{K_H S_H}\right)^2 + R_T \left(\frac{\Delta C'_{ab}}{K_C S_C}\right) \left(\frac{\Delta H'_{ab}}{K_H S_H}\right)} \quad (6)$$

$$\Delta E_{\text{色差}} = \frac{1}{\Delta E_{\text{CIE2000}}}$$

其中, $\Delta L'$ 、 $\Delta C'_{ab}$ 和 $\Delta H'_{ab}$ 分别是2个超像素之间的平均明度差值、彩度差值和色相差值; S_L 、 S_C 和 S_H 为权重函数,它们定义了颜色空间中椭圆半轴的长度,允许在Lab颜色空间中根据区域的不同进行调整,从而校正该空间的均匀性; K_L 、 K_C 和 K_H 是与使用条件相关的校正系数,在CIE给定的标准观测条件下, K_L 、 K_C 和 K_H 都等于1; R_T 为旋转函数。

$\Delta L'$ 、 $\Delta C'_{ab}$ 和 $\Delta H'_{ab}$ 的计算公式如式(7)所示。

$$\Delta L' = L'_1 - L'_2, \Delta C'_{ab} = C'_{ab,1} - C'_{ab,2}, \Delta H'_{ab} = 2 \times \sqrt{C'_{ab,1} C'_{ab,2}} \times \sin\left(\frac{\Delta h'_{ab}}{2}\right), \Delta h'_{ab} = h'_{ab,1} - h'_{ab,2} \quad (7)$$

其中, L' 、 C'_{ab} 和 h'_{ab} 的定义如式(8)所示。

$$L' = L^*, a' = (1 + G) \times a^*, b' = b^*, C'_{ab} = \sqrt{a' \times a' + b' \times b'}, h'_{ab} = \tan^{-1}\left(\frac{b'}{a'}\right) \quad (8)$$

其中, G 表示CIE1976LAB颜色空间的轴的调整因子,是与彩度有关的函数,定义如式(9)所示。

$$G = 0.5 \times \left(1 - \sqrt{\frac{\overline{C_{ab}^*}^7}{\overline{C_{ab}^*}^7 + 25^7}}\right) \quad (9)$$

其中, $\overline{C_{ab}^*}$ 等于 $C_{ab,1}^*$ 和 $C_{ab,2}^*$ 的算术平均值 $C_{ab}^* = \sqrt{a^* \times a^* + b^* \times b^*}$ 。

S_L 、 S_C 和 S_H 的计算公式如式(10)所示。

$$S_L = 1 + \frac{0.015 \times (\overline{L'} - 50)^2}{\sqrt{20 + (\overline{L'} - 50)^2}}, S_C = 1 + 0.045 \times \overline{C'_{ab}}, S_H = 1 + 0.015 \times \overline{C'_{ab}} \times T \quad (10)$$

其中, T 的定义如式(11)所示。

$$T = 1 - 0.17 \times \cos(\overline{h'_{ab}} - 30^\circ) + 0.24 \times \cos(2\overline{h'_{ab}}) + 0.32 \times \cos(3\overline{h'_{ab}} + 6^\circ) - 0.2 \times \cos(4\overline{h'_{ab}} - 63^\circ) \quad (11)$$

R_T 的定义如式(12)所示。

$$R_T = -\sin(2\Delta\theta) \times R_c \quad (12)$$

其中, $\Delta\theta$ 是由色调决定的旋转角, R_c 是根据彩度变化的旋转幅度,定义如式(13)所示。

$$\Delta\theta = 30 \times \exp\left[-\left(\frac{\overline{h'_{ab}} - 275^\circ}{25}\right)^2\right], R_c = 2 \times \sqrt{\frac{\overline{C_{ab}^*}^7}{\overline{C_{ab}^*}^7 + 25^7}} \quad (13)$$

1.6.2 特征相似项

取2个超像素的修正余弦相似度,记为 $\Delta E_{\text{特征相似度}}$,计算公式如式(14)所示。

$$\Delta E_{\text{特征相似度}} = \frac{1 + \cos(\theta)}{2} \quad (14)$$

1.6.3 评估增益项

评估增益项的计算公式如式(15)所示。

$$\Delta E_{\text{评估增益项}} = \max(\{p_{i,a} p_{i,b}, i \in K\}) \quad (15)$$

评估增益项是取2个超像素各自的K个分类结果对应相乘后的最大值,可以定义为具有相似的评估信息的2个超像素会得分更高。

最终评估相似度的计算公式如式(16)所示。

$$\Delta E_{\text{评估相似度}} = \Delta E_{\text{评估增益项}} \times \Delta E_{\text{色差}} \times \Delta E_{\text{特征相似度}} \quad (16)$$

根据得出的评估相似度,可以用于下一轮主动学习的消息传递。

1.7 时空复杂度分析

因为本文不涉及对分类模型与查询策略的选取与改进,故仅讨论评估相似度的计算与消息传递对主动学习产生的时空代价。在一幅被分割成 n 个超像素的遥感图片上,对其建立超像素区域邻接图的操作是遍历每个超像素的轮廓外沿,时间复杂度为 $O(n)$ 。若平均超像素的邻居节点个数为 m ,存储该区域邻接图信息的空间复杂度为 $O(nm)$ 。评估相似度涉及对图上所有节点对的计算,即需要遍历所有的边,故计算评估相似度的时间复杂度为 $O(nm)$ 。下一步需要对所有节点的消息计算与消息聚合,这两步的时间复杂度为 $O(n)$ 与 $O(nm)$,故每轮的评估相似度计算到消息传播的时间复杂度为 $O(nm)$,当需要进行 k 轮次的消息传播时为 $O(knm)$ 。值得一提的是,由于SLIC分割算法得出的超像素具有紧致、大小均匀和网格化等特点,可以近似为六边形蜂窝排列或是网格排列。超像素区域邻接图中的每个节点平均有6~8个邻接节点,即 m 的取值在6~8之间,远小于超像素个数 n 。因此,在实际运行中,本文算法的时间复杂度可以近似为 $O(kn)$ 。

2 实验与结果分析

2.1 数据集与相关实验参数

本文提出的主动学习算法不涉及分类模型的优化,在实验部分选取具有代表性的梯度提升决策树模型(xgboost, XGB)作为分类模型。同时,本文也不涉及对查询策略的修改,故选取常见的3种查询策略:熵采样(Entropy Sampling, ES)^[29]、边界采样(MarginSampling, MS)^[30]和不确定性采样(Uncertainty Sampling, US)^[15]。在基于池的主动学习中,分类模型在进入主动学习前需要一个包含全部类别的初始化样本集,用于将分类模型进行初始化。初始

化样本集由各类别随机选取一个超像素构成,后续实验均为平行设置 10 组取均值。

本文选取了多分类标注的数据集 FloodNet^[31]和 Vaihingen^[32]。FloodNet 数据集包含了 2017 年 8 月 30 日—9 月 4 日期间在得克萨斯州福特本德县进行的多次遥感记录,图像中包含红色、绿色和蓝色 3 个常见波段。在消融实验和样本数量实验中,将展示具有代表性的图片,编号分别为 FloodNet-7577;在对比实验中,为了进一步验证其有效性,加入了另一具有代表性的图片 FloodNet-9105。Vaihingen 数据集则包含 33 幅不同尺寸的遥感图像,这些图像分别从更大的顶层正射影像中提取,避免了数据缺失的问题。图像的空间分辨率为 9cm,格式为 8 位 TIFF 文件,包含近红外、红色和绿色 3 个波段。在消融实验和样本数量实验中,将展示具有代表性的图片,编号分别为 Vaihingen-17;在对比实验中,为了说明算法在该数据集上的有效性,加入了另一具有代表性的图片 Vaihingen-37。相关实验参数,如表 1 所示。

Table 1 Experimental parameters
表 1 实验参数表

数据集	图像大小/px	超像素数目/个	主动学习采样数量
			占比/%
FloodNet-7577	4 592×3 072	13 085	3.82
FloodNet-9105	4 000×3 000	11 555	4.33
Vaihingen-17	2 336×1 281	8 671	5.77
Vaihingen-37	1 996×1 995	10 694	4.68

2.2 评价指标

2.2.1 总体准确率(Overall Accuracy, OA)

$$OA = \frac{\text{正确分类像素数}}{\text{总像素数}} \tag{17}$$

公式(17)是超像素分类结果再重新映射回像素上的总体准确率。

2.2.2 平均准确率(Average Accuracy, AA)

$$AA = \frac{1}{C} \sum_{i=1}^C \frac{TP_i}{TP_i + FN_i} \tag{18}$$

公式(18)是 C 个类别中分类正确像素数量除以该类的真实像素数,即各类别的平均准确率。

2.2.3 卡帕系数(Kappa)

$$PE = \sum_{i=1}^C (\frac{\text{样本数}_i}{\text{总样本数}})^2 \tag{19}$$
$$Kappa = \frac{OA - PE}{1 - PE}$$

公式(19)中的 PE 是预期准确率,Kappa 系数反映分类结果与预期的一致程度。Kappa=1 表示完全一致,Kappa=0 表示随机猜测,Kappa<0 则表示比随机猜测的结果更差。

2.3 消融实验

利用图结构获取邻域信息特征是一种常见的特征编码手段。以传统特征工程为例,将邻居超像素的自身特征叠加后取平均值是最基本的编码方式,也是本文消息传递算法的初始化编码。同时,在消融实验中以不进行消息传

递和仅传递色差信息作为 2 个对比基准,实验结果如表 2 所示。

Table 2 Ablation experiment result
表 2 消融实验结果

图片	消息传播	查询策略	OA	AA	Kappa
FloodNet-7577	无	ES	0.846 8	0.615 8	0.794 1
		MS	0.846 8	0.600 2	0.792 7
		US	0.838 7	0.527 0	0.782 2
	色差	ES	0.855 9	0.614 6	0.805 7
		MS	0.875 9	0.659 8	0.833 1
		US	0.856 1	0.625 4	0.806 5
		ES	0.884 0	0.713 4	0.844 4
	评估相似度	MS	0.883 0	0.666 6	0.842 3
		US	0.876 0	0.646 5	0.832 8
		ES	0.850 4	0.704 8	0.774 7
Vaihingen-17	无	MS	0.849 2	0.688 1	0.772 7
		US	0.845 3	0.693 1	0.772 3
		ES	0.863 7	0.714 7	0.795 9
	色差	MS	0.857 5	0.722 3	0.790 0
		US	0.858 7	0.705 5	0.792 0
		ES	0.867 3	0.734 9	0.804 7
		MS	0.862 6	0.698 7	0.794 9
	评估相似度	US	0.869 4	0.713 4	0.805 5

由表 2 可知,相比较于基线算法,本文算法利用消息传递机制在 ES、MS 和 US 这 3 种常规查询策略下,均获得了高于基线模型的性能表现。在 FloodNet-7577 数据集上,基于评估相似度的消息传播机制与 ES 查询策略的组合在 3 种指标中取得了最优的结果,这表明本文提出的评估相似度能够有效提升分类模型性能。然而,在 FloodNet-7577 数据集上,仅使用色差作为消息传递的结果时,其与 ES 的组合在 AA 得分上低于基线,这表明仅使用色差作为消息传递的消息并不完全可靠,会出现类别预测不均衡的问题。在 Vaihingen-17 数据集上,无论是基于色差还是评估相似度的消息传递机制,分类性能均显著高于基线。在评估相似度的消息传递机制中,最优的 OA 和 Kappa 得分是在 US 查询策略下取得的,而最优的 AA 得分则是在 ES 查询策略下实现的。不过,在 ES 查询策略下取得的 OA 和 Kappa 得分虽然次优,但与最优结果的差距并不大。

综上所述,消息传递机制能够有效提供合理的空间信息,而评估相似度的提出能够优化超像素分类的准确性,并在多种查询策略上提升性能。FoodNet-7577 消融实验结果的细节展示,如图 4 所示。

由图 4 可知,FloodNet-7577 基线实验中采用了 ES 查询策略,展示了两处具有代表性的细节。从基线算法的分类结果来看,虽然大多数地物整体已被分类,但在许多地物内部仍存在大量错误分类的超像素。这类内部错误在基于色差或是评估相似度的消息传递算法中得到改善,证明了消息传递机制与主动学习相结合的优势。在细节方面,从基线算法第一行细节图可以看出,建筑物内部小部分的区域被基线算法错误分类。通过本文基于色差的消




Fig. 4 FloodNet-7577 details display (ES query strategy)

图4 FloodNet-7577细节展示(ES查询策略)

文基于评估相似度的消息传递算法,则进一步缓解了该区域的分类错误,表现水平显著高于基线,并且优于仅使用色差的方法,使得建筑物的分类结果更加完整。但从各算法的整体分类效果来看,对于细小地物的分类效果并不理想,这可能是由于数据样本中类别分布不均衡所导致的。

综上所述,本文中的消息传递机制能够有效解决同属于一个地物的大片区域内出现的错误超像素分类问题,而本文提出的评估相似度比传统利用颜色差异的色差权值更适合在主动学习中进行消息传递,进而提升整体分类性能,得到更为完整的地物分类结果。

2.4 样本数量实验

主动学习的重要优势是可以使用较少的样本数量达到较优的效果,从而节省人工标注的开销。本文研究了在不同的查询总量情况下,本文算法与基线算法的准确性。在给定总查询数量为500的情况下,每进行20个样本的学习查询后记录OA、AA和Kappa,实验的其他设置同上。如图5和图6所示,以OA、AA和Kappa作为评价指标,分别为FloodNet-7577和Vaihingen-17数据集的评估相似度(ES查询策略)曲线。




Fig. 5 FloodNet-7577 evaluates similarity (using ES query strategy)

图5 FloodNet-7577评估相似度(ES查询策略)曲线




Fig. 6 Vaihingen-17 evaluates similarity (using ES query strategy)

图6 Vaihingen-17评估相似度(ES查询策略)曲线

通过对图 5 和图 6 的分析可知,当查询总数设为 500 时,本文算法在 OA、AA 及 Kappa 等评估指标上均显著优于基线算法。具体而言,图 5(a)和图 5(c)中,在查询样本数达到 140 左右前,本文算法在 OA 和 Kappa 得分上暂时落后于基线。这主要是因为主动学习初期监督信号有限,导致预测错误较多。本文算法的消息传递将这些预测错误的信息进行传播,从而影响了模型性能。然而,随着专家标记样本数量增加,分类模型获得更多监督信息,本文算法性能也会迅速提升,与基线算法拉开差距。值得注意的是,样本量不足导致性能下降并非必然现象,从图 6(a)、图 6(b)和图 6(c)的训练样本曲线可知,在整个实验过程中,本文算法各项指标始终优于基线算法,且训练过程保持平滑。综上所述,本文算法的消息传递机制整体有效,但将评估相似度作为消息传递权重的设计,需要达到一定样本量才能充分发挥其提升效果。

2.5 对比实验

在对比实验中,特征工程与分割参数保持一致。由于本文算法通过改动主动学习流程并进行超像素分类进行改进,因此,选取同样改动主动学习流程的模型 SNSL 进行对比。此外,本文算法主要利用超像素的空间信息,与利用样本频域信息的主动学习算法 BSDE 进行比较^[33]。本文算法同时利用了超像素区域邻接图结构及消息传播机制,因此在同等比例的随机采样上,对经典的图结构监督模型 GCN 与 GAT 进行了对比。同时,等比例的随机采样也作为补充实验。对比实验结果如表 3 所示。

Table 3 Comparative experiment result							
表 3 对比实验结果							
数据集	指标	SSNSL ^[23]	GCN ^[24]	GAT ^[25]	BSDE ^[33]	Random	本文算法
FloodNet-7577	OA	0.853	0.803	0.795	0.877	0.798	0.884
	AA	0.640	0.519	0.491	0.657	0.493	0.713
	Kappa	0.802	0.756	0.725	0.812	0.732	0.844
FloodNet-9105	OA	0.851	0.762	0.791	0.850	0.754	0.853
	AA	0.764	0.601	0.651	0.743	0.501	0.780
	Kappa	0.789	0.714	0.732	0.774	0.746	0.795
Vaihingen-17	OA	0.849	0.768	0.784	0.858	0.795	0.867
	AA	0.735	0.568	0.597	0.744	0.638	0.732
	Kappa	0.782	0.667	0.684	0.791	0.711	0.805
Vaihingen-37	OA	0.831	0.786	0.768	0.818	0.773	0.838
	AA	0.689	0.631	0.637	0.663	0.595	0.696
	Kappa	0.763	0.687	0.675	0.746	0.679	0.774

图 7 为对比实验结果的细节展示,每组分图从上至下依次为 FloodNet-7577、FloodNet-9105、Vaihingen-17 和 Vaihingen-37。由表 3 可知,本文算法优于仅使用 XGB 进行随机标注的模型,表示主动学习在训练过程中有效的挑选出了值得标注的样本。而对比于同样是利用超像素空间信息的 SSNSL 模型,本文算法也在 FloodNet 与 Vaihingen 两个数据集上取得更高的 OA 得分与 Kappa 得分。通过对比图 7(e)和图 7(g)可以看出,在 FloodNet-7577 和 Vaihingen-37 数据集上的分类结果中,SSNSL 对中型地物的分类效果不如本文算法,例如 FloodNet-7577 中的勺状地区。这主要是因为 SSNSL 是依据颜色信息构建的超像素社区,这样的社区构建方式较为紧密,但伸展上不足,无法充分




Fig. 7 Detailed diagram of comparative experiment result

图 7 对比实验结果细节图

考虑地物远端的空间信息。而本文算法通过消息传递与评估相似度的机制,不仅限于颜色上的关联,更加关注分类模型本身的预测结果,因此能够更完整地分类 FloodNet-7577 中的勺状区域。通过对比图 7(f) 和图 7(g) 可以看出,BSDE 通过预先对样本聚类,再选取代表性更好的样本,能够在特征明显的地物中取得较好的效果。然而,当面对包含大量阴影的复杂场景(如 FloodNet-9105 数据集)时,传统算法容易产生误判。本文提出的基于评估相似度的消息传递机制不同于固定特征相似性的传统方法。它通过分类模型的迭代优化,逐步建立准确的空间关联。实验结果表明,该机制在强阴影场景下仍保持较高的检测精度。与同为图结构与消息传递框架的 GCN 和 GAT 模型相比,本文算法展现出显著优势。

综上所述,当地物能够被超像素分割成多个部分时,本文算法能够结合各个部分的空间信息,从而提高地物分类的完整性和准确率。然而,当遇到无法有效分割的小型地物时,本文算法可能会受到一定的限制。

3 结语

本文提出的基于超像素区域邻接图和消息传递的主动学习算法,充分利用了分类模型产生的评估信息和超像素的空间信息,挖掘了主动学习在遥感图像上的应用研究,提升了以超像素作为样本的分类性能。构建超像素区域邻接图,通过区域邻接图进行消息传播,致力于解决不同地物间的相似超像素和同一地物间非相似超像素的识别难题。此外,本文方法涉及在图上每个节点进行运算,如何在保证模型性能的同时节省运算开销并优化时间效率是未来工作研究的重点。

参考文献:

- [1] FENG Q, TANG C, CHEN M, et al. Field investigation and research on debris flow on August 20, 2019 in Mianshi town, epicenter of Wenchuan earthquake[J]. Journal of Disaster Prevention and Mitigation Engineering, 2022, 42(1): 51-59.
丰强,唐川,陈明,等.汶川震区绵虬镇"8·20"登溪沟泥石流灾害调查与分析[J]. 防灾减灾工程学报, 2022, 42(1): 51-59.
- [2] CHENG T, LIU R M, ZHOU X. Water information extraction method in geographic national conditions investigation based on high resolution remote sensing images[J]. Bulletin of Surveying and Mapping, 2014(4): 86-89.
程滔,刘若梅,周旭.基于高分辨率遥感影像的地理国情普查水体信息提取方法[J]. 测绘通报, 2014(4): 86-89.
- [3] MAO W. Fusion spectral clustering and multifeature remote sensing image segmentation[J]. Software Guide, 2020, 19(3): 248-251.
冒伟.融合谱聚类和多特征的遥感图像分割[J]. 软件导刊, 2020, 19(3): 248-251.
- [4] LI Z Y, DAI J Q, HUANG D, et al. Application and prospects of satellite remote sensing monitoring technology in water conservancy projects[J]. Advances in Water Science, 2023, 34(5): 798-811.
李子阳,戴济群,黄对,等.水利工程卫星遥感监测技术应用与展望[J]. 水科学进展, 2023, 34(5): 798-811.
- [5] LIU S C, DU K C, ZHENG Y J, et al. Remote sensing change detection technology in the era of artificial intelligence: inheritance, development and challenges[J]. National Remote Sensing Bulletin, 2023, 27(9): 1975-1987.
柳思聪,都科丞,郑永杰,等.人工智能时代的遥感变化检测技术:继承,发展与挑战[J]. 遥感学报, 2023, 27(9): 1975-1987.
- [6] WANG Y, LIU C, TANG J G. Fuzzy cmeans remote sensing image segmentation algorithm with adaptive multidimensional feature reduction[J]. Application Research of Computers, 2022, 39(3): 906-910.
王媛,刘丛,唐坚刚.自适应多维特征减少的模糊C-均值遥感图像分割算法[J]. 计算机应用研究, 2022, 39(3): 906-910.
- [7] ZHANG Y, ZHANG J. Frequency domain feature extraction method and application of highresolution remote sensing image of debris flow[J]. Bulletin of Surveying and Mapping, 2023(3): 111-115.
张悦,张锦.泥石流高分辨率遥感影像频域特征提取方法及应用[J]. 测绘通报, 2023(3): 111-115.
- [8] CHEN X M, LIU Z H, ZHOU S P, et al. Road extraction from high-resolution remote sensing images based on HRNet[J]. Systems Engineering and Electronics, 2024, 46(4): 1167-1173.
陈雪梅,刘志恒,周绥平,等.基于HRNet的高分辨率遥感影像道路提取方法[J]. 系统工程与电子技术, 2024, 46(4): 1167-1173.
- [9] TAO J X, PAN B, KONG X D, et al. Color transfer based on image semantic region guidance based on superpixel[J]. Application Research of Computers, 2020, 37(7): 2217-2221, 2240.
陶金鑫,潘斌,孔晓迪,等.基于超像素的图像语义区域引导的色彩迁移[J]. 计算机应用研究, 2020, 37(7): 2217-2221, 2240.
- [10] ZHAO Z Z, FANG M Y, GAO Z, et al. Study on SLIC segmentation and region merging method of lowaltitude remote sensing images with fused elevation information[J]. Bulletin of Surveying and Mapping, 2023(4): 35-40.
赵宗泽,方明源,高钊,等.融合高程信息的低空遥感影像SLIC分割和区域合并方法[J]. 测绘通报, 2023(4): 35-40.
- [11] YANG H Y, ZHANG C F, YANG J W, et al. SLIC superpixel segmentation algorithm based on convex hull[J]. Software Guide, 2023, 22(3): 153-156.
杨昊宇,张春富,杨佳武,等.基于凸包的SLIC超像素分割算法[J]. 软件导刊, 2023, 22(3): 153-156.
- [12] LIU C, TUO M W, GAN Z J Y, et al. Research on multiple visual features image segmentation algorithm based on superpixel[J]. Software Guide, 2021, 20(12): 146-151.
刘丛,唐明炜,甘张俊逸,等.基于超像素的多视觉特征图像分割算法研究[J]. 软件导刊, 2021, 20(12): 146-151.
- [13] STUTZ D, HERMANS A, LEIBA B. Superpixels: an evaluation of the state-of-the-art[J]. Computer Vision and Image Understanding, 2018, 166: 1-27.
- [14] YANG Y F. Objectoriented target extraction from highresolution remote sensing images[J]. Computer Science and Applications, 2023, 13(11): 2022-2029.
杨云飞.面向对象高分辨率遥感影像目标提取[J]. 计算机科学与应用, 2023, 13(11): 2022-2029.
- [15] LEWIS D D, GALE W A. A sequential algorithm for training text classifiers: corrigendum and additional data[J]. ACM SIGIR Forum, 1995, 29(2): 13-19.

- [16] ANGLUIN D. Queries and concept learning [J]. Machine learning, 1988, 2: 319–342.
- [17] COHN D, ATLAS L, LADNER R. Improving generalization with active learning[J]. Machine Learning, 1994, 15: 201–221.
- [18] MANTRIPRAGADA K, QUINTANILHA J A, et al. Active learning classification and change detection on multispectral images [C]//2014 12th IEEE International Conference on Industrial Informatics (INDIN), 2014: 26–30.
- [19] LIU W S, YANG J, LI P X, et al. A novel objectbased supervised classification method with active learning and random forest for polsar imagery [J]. Remote Sensing, 2018, 10(7): 1092.
- [20] SU T F, ZHANG S W, LIU T X. Multispectral image classification based on an objectbased active learning approach [J]. Remote Sensing, 2020, 12(3): 504.
- [21] MA L, FU T Y, LI M C. Active learning for objectbased image classification using predefined training objects [J]. International Journal of Remote Sensing, 2018, 39(9): 2746–2765.
- [22] LI Y. Hyperspectral image classification based on pixel-sub-pixel-super-pixel level multifeature combination [D]. Changsha: Hunan University, 2020.
李煜. 基于像素-亚像素-超像素级多特征联合的高光谱图像分类 [D]. 长沙: 湖南大学, 2020.
- [23] TANG J C, TONG H J, TONG F, et al. Exploiting superpixelbased contextual information on active learning for high spatial resolution remote sensing image classification [J]. Remote Sensing, 2023, 15(3): 715.
- [24] KIPF T N, WELING M. Semisupervised classification with graph convolutional networks [DB/OL]. <https://arxiv.org/abs/1609.02907>.
- [25] VELIČKOVIĆ P, CUCURULL G, CASANOVA A, et al. Graph attention networks [C]//Vancouver: International Conference on Learning Representations (ICLR), 2018.
- [26] ACHANTA R, SHAJI A, SMITH K, et al. SLIC superpixels compared to state of the art superpixel methods [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2012, 34(11): 2274–2282.
- [27] CHENG H D, JIANG X H, SUN Y, et al. Color image segmentation: advances and prospects [J]. Pattern Recognition, 2001, 34(12): 2259–2281.
- [28] LEVINSHTEIN A, STERE A, KUTULAKOS K N, et al. Turbopixels: fast superpixels using geometric flows [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2009, 31(12): 2290–2297.
- [29] LAFFERTY J, MCCALLUM A, PEREIRA F C N. Conditional random fields: probabilistic models for segmenting and labeling sequence data [C]// Proceedings of the Eighteenth International Conference on Machine Learning, 2001: 282–289.
- [30] SCHEFFER T, DECOMAIN C, WROBEL S. Active hidden Markov models for information extraction [C]//International Symposium on Intelligent Data Analysis, 2001: 309–318.
- [31] RAHNEMOONFAR M, CHOWDHURY T, SARKAR A, et al. Floodnet: a high resolution aerial imagery dataset for post flood scene understanding [J]. IEEE Access, 2021, 9: 89644–89654.
- [32] ROTTENSTEINER F, SOHN G, JUNG J, et al. The ISPRS benchmark on urban object classification and 3D building reconstruction [J]. ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 2012, 1–3: 293–298.
- [33] HU F, LI L Z, DAI J, et al. Active learning combined with clustering boundary sampling [J]. CAAI Transactions on Intelligent Systems, 2024, 19(2): 482–492.
胡峰, 李路正, 代劲, 等. 结合聚类边界采样的主动学习 [J]. 智能系统学报, 2024, 19(2): 482–492.

(责任编辑: 陈维捷)