文章编号: 1672-8785(2023)05-0032-14

基于多尺度样本扩增的高光谱 影像半监督分类

刘丽丽¹ 杨春蕾^{1*} 顾明剑^{1,2,3} 胡 勇^{1,2,3}
(1.中科技术物理苏州研究院,江苏苏州 215000;
2.中国科学院上海技术物理研究所,上海 200083;
3.中国科学院红外探测与成像技术重点实验室,上海 200083)

摘 要:大量的训练样本可有效缓解模型过拟合,从而提高分类效果。在初始标记样本较少的情况下,开展借助不同尺度的同质区快速扩增大量高精度训练样本的实验,并利用初始标记样本和扩增样本训练支持向量机(Support Vector Machine, SVM)分类器,实现对高光谱数据的有效分类。该方法在 Pavia University、Salinas 和 Indian Pines 三种高光谱数据上均能获得大量高精度的训练样本,分类精度分别达到 99%、99%和 97%以上。实验结果表明,扩增的大量伪标签样本可以有效训练 SVM 分类器,提高分类效果。

关键词: 高光谱影像; 半监督分类; 多尺度同质区; 训练样本扩增; 图像分割; 支持向量机

中图分类号: P237 文献标志码: A DOI: 10.3969/j.issn.1672-8785.2023.05.005

Semi-Supervised Classification of Hyperspectral Images Based on Multi-Scale Sample Amplification

LIU Li-Ii¹, YANG Chun-Iei^{1*}, GU Ming-jian^{1,2,3}, HU Yong^{1,2,3}

(1. Suzhou Academy, Shanghai Institute of Technical Physics, Chinese Academy of Sciences, Suzhou 215000, China;
2. Shanghai Institute of Technical Physics, Chinese Academy of Sciences, Shanghai 200083, China;

3. Key Laboratory of Infrared Detection and Imaging Technology, Chinese Academy of Sciences, Shanghai 200083, China)

Abstract: A large number of training samples can effectively alleviate the overfitting of the model and improve the classification effect. A lot of high-precision training samples are rapidly amplified by using homogenous regions of different scales. The support vector machine classifier is trained with the initial labeled samples and amplified samples to achieve the effective classification of hyperspectral data. The majority of high-precision training samples based on Pavia University data, Salinas data and Indian Pines data can be obtained by this method, and the accuracy is above 99%, 99% and 97% respectively. The experiment results show that the large number of pseudo-label samples amplified by the proposed method can effectively train the SVM classifier and improve the classification effect.

收稿日期: 2023-01-03 作者简介: 刘丽丽(1990-), 女,河南巩义人,硕士研究生,主要从事遥感图像分析和处理方面的研究。 *通讯作者: E-mail: 2932361426@qq.com **Key words:** hyperspectral image; semi-supervised classification; multi-scale homogeneous regions; training sample amplification; image segmentation; SVM

0 引言

标记样本对遥感影像的分类至关重要,但 是其往往不易获取且成本高。少量的标记样本 会降低分类器的泛化能力和分类精度。如何利 用较少训练样本实现高分类精度已成为遥感领 域的重要研究方向和亟待解决的难题^[1]。

图像分割技术具有解决这一问题的潜在优势。图像分割的方法很多,通常根据相邻像素 点的灰度差异^[2]被分为基于阈值的分割方 法^[3]、基于区域的分割算法^[4]、基于边缘的分 割算法^[5]等。虽然已提出的图像分割方法很 多,但是实现图像的高纯度分割依然具有挑战 性。高精度的图像分割^[6]可将高光谱图像切割 成互不重叠的高精度同质区斑块。同质区域内 的像素需要满足某种相似性准则,相邻的同质 区域之间具有明显的差异^[7]。在高精度同质区 内,像素点的类别一致。通过对同质区内的未 知点赋予与初始标记点相同的标签,即可达到 扩增训练样本的目的,从而实现半监督分类。

目前,高光谱影像的半监督分类方法主要 有基于生成式模型的方法^[8]、基于低密度划分 的方法^[9]、基于图的半监督学习方法^[10]、协 同训练方法^[11]等。高光谱影像的半监督分类 利用标记样本和未标记样本之间的关系得到伪 标记样本,在一定程度上能够提高分类器的分 类精度和泛化能力,从而提高分类性能。这对 遥感图像分类具有重要意义。Cui B 等^[12]提出 了一种基于超像素的扩展标签传播算法。他们 利用超像素和标签传播算法扩增大量的伪标签 样本,并将其作为 SVM 的训练集,在高光谱 图像上取得了很好的分类效果。Amini S 等^[13] 提出了一种基于半监督随机森林算法的高光谱 图像分类方法。该方法通过用标记样本进行随 机森林分类来得到未标记数据的类别概率,并 根据概率和温度参数扩增训练样本,最终对高 光谱图像实现了较好的分类效果。周绍光 等^[14]通过对目标图像进行分割来得到同质区, 并将其用于扩增目标域的训练样本数量,提高 了对高光谱图像进行半监督迁移学习分类的效 果。现有的同质区扩增训练样本的半监督分类 方法都仅用单一尺度的同质区扩增样本,且未 考虑较大同质区斑块边缘的噪声点,直接影响 了扩增样本的数量和精度。目前半监督分类获 得的扩增样本的精度直接影响分类效果,因此 如何获得大量高精度的扩增样本是现在面临的 难题。

本文借助两种不同尺度的同质区扩增训练 样本,但目前面临两个难题:(1)如何获得高 纯度的同质区;(2)如何在同质区不纯的情况 下减少标记点的错误点扩增。针对上述问题, 本文通过同质区获得大量高精度的扩增样本, 并对 SVM 进行有效训练,从而用小样本对三 种常见的高光谱影像进行有效分类。

1 方法

下面先介绍基于不同尺度同质区的生成方法,然后详细阐述基于同质区的训练样本扩增 方法,最后分析高光谱影像分割以及分类的评价指标。

1.1 不同尺度同质区的生成

本文采用不同的分割方法生成不同尺度的 同质区:利用基于静态图像压缩标准(J-value SEGmentation,JSEG)的分割方法生成较大尺 寸的同质区,并用简单线性迭代聚类(Simple Linear Iterative Clustering,SLIC)分割方法生 成较小面积的同质区。同质区生成的具体流程 (见图 1)如下:提取高光谱图像的前三主成 分,在JSEG分割的基础上对不纯的斑块进行 均值漂移提纯,最后将孤立点与周围的大同质 区斑块合并,生成JSEG 同质区;SLIC 同质区 生成时设置合适的分割斑块数并进行简单的超



图 1 不同尺度同质区生成算法的流程图

像素分割,得到 SLIC 同质区。下面具体介绍 JSEG 分割、SLIC 分割以及均值漂移算法。

1.1.1 JSEG 分割算法

JSEG 分割算法主要包括颜色量化和空间 分割^[15]。颜色量化是将原图像中不重要的相 似颜色合并为一种颜色,其目的是提取图像中 具有代表性的颜色来区分相邻区域。在颜色量 化图中,像素值是量化后颜色类别的标号,不 同的像素值代表量化后的不同颜色。

图 2 是以高光谱图像为例的 JSEG 分割流 程图。首先,提取高光谱图像的前三主成分作 为 RGB 图并进行 Kmeans 聚类;其次,选择合



图 2 JSEG 分割算法的流程图

适的窗口尺寸计算 J 值, 生成多尺度 J 图像; 最后在多尺度 J 图像的基础上选择局部 J 值小 于阈值的点作为种子点,将其邻域中与种子点 相似的像素合并到一起,最终得到 JSEG 分 割图。

1.1.2 SLIC 分割算法

SLIC 分割算法由 Achanta R 等^[16]在 2010 年提出,能够较好地表达地物间的纹理信息, 提高地物边界的依附性^[17]。SLIC 超像素在分 割斑块数目较多的情况下可得到纯度很高的同 质区,因此本文利用 SLIC 算法生成较小尺寸 的同质区。

图 3 为 SLIC 分割算法的流程图。首先, 从全图中选择 k 个点作为聚类的中心点。为了 防止聚类中心位于边界处,将其移到邻域内最 小梯度距离所在的位置。其次,将图像中的所 有像素都进行聚类分析,计算每个像素与所有 聚类中心之间的距离,寻找到各个像素距离最 小的聚类中心点,并将其归属于该聚类。最后 重新计算该聚类中所有点的平均向量并将其作 为下次聚类的中心,接着重复上述过程直至收 敛为止。

1.1.3 均值漂移算法

经过分割后,对纯度很高的斑块再提纯不 仅不会提高分割的纯度,反而会增加斑块的数 量。因此本文对同质区斑块进行筛选,只对不 纯的斑块用均值漂移算法^[18]进行提纯。本文



红 外



图 3 SLIC 分割算法的流程图

将斑块的平均方差作为衡量斑块纯度的指标。 平均方差越大,斑块纯度越小。平均方差的公 式为

$$Var_{mean} = \frac{1}{c} \sum_{j=1}^{c} \left[\frac{1}{N} \sum_{i=1}^{N} (x_i - \bar{x})^2 \right]$$
(1)

式中, c 代表高光谱影像的总波段数, N 为斑 块中的像素数, x_i 为斑块中第 i 个元素的特征 向量, \bar{x} 代表斑块的特征中心。

大量实验结果表明,纯斑块的比例远高于 50%,取小于 50%的值作为阈值时都能将所 有的不纯斑块提纯。为了避免调整参数带来的 麻烦,本文始终取 50%作为阈值。

1.2 训练样本扩增方法

为了提高扩增训练样本的精度,本文对不 同尺度的同质区采用不同的方法扩增训练 样本。

1.2.1 大尺度同质区扩增样本

对于 JSEG 分割方法产生的大尺度同质 区,部分同质区斑块内元素较多且会产生欠分 割现象。若直接将标记斑块(即含有标记样本的同质区斑块)内所有元素赋予和标记点相同的标签,则会增加错误点的数量。为了减小由于斑块不纯导致的同质区扩增点的错误率并确保扩增样本的质量,大尺度同质区采用 K 近邻算法扩增训练样本(仅扩增标记斑块中距离初始训练样本近的点)。K 没有固定值,由同质区斑块中元素的数量确定。本文实验中所有标记斑块的 K 值均为斑块元素数量的一半。经大量实验证明,此时效果最好。

当 K 值确定后,用 K 近邻算法扩增训练 样本的具体过程如下:

(1)同质区斑块内的元素个数为 n,标记 点个数为 j,第 k 个无标记点的特征向量为 U_k $= u_1, u_2, \dots, u_n$,第 i 个标记点的特征向量为 $L_i = l_1, l_2, \dots, l_n$ 。根据欧氏距离公式,计算 U_k 和 L_i 之间的距离:

$$dist_{k,i} = \sqrt{(U_k - L_i)^2} \tag{2}$$

(2)将该同质区斑块中的 *n*-*k* 个无标记点
到第 *i* 个标 记点的距离 *dist* = *sort*(*dist*_{1,i}, *dist*_{2,i}, …, *dist*_{n-k,i})按降序排列。

(3)选择距离该标记点最近的 K 个无标记 点,并赋予与该标记点相同的标签。

(4)返回步骤(1),直到遍历完 *j*个标记 点。

(5)统计无标记点出现的标签频率。若某 个无标记点多次出现,则去除标签不同的无标 记点以及标签相同的重复无标记点。

1.2.2 小尺度同质区扩增样本

SLIC 分割方法产生的斑块数量较多且斑 块内元素数量较均匀。这种分割方法产生大量 的过分割斑块,使得同质区斑块纯度极高。本 文采用简单的多数投票策略对标记斑块的标签 进行投票,寻找斑块内标记样本的标签众数作 为斑块标签。具体如下:

(1)当种子斑块内只有一个标记点时,斑块 内元素的标签众数即为该标记点的标签。此时 将斑块内的所有点赋予和标签众数相同的标签。

(2)当斑块内有多个同一类别的标记点

35

时,斑块标签即为该类别标签。此时将斑块 内所有点赋予和该标记点相同的标签。

(3)当种子斑块内有不同类别的标记点 时,需对所有的标记点标签进行投票,选取 标记样本的标签众数作为斑块标签。保持标 记样本的标签不变,并将斑块内其他元素赋 予和该斑块标签相同的标签。

1.3 评价方法

1.3.1 同质区纯度评价指标

高光谱遥感影像的同质区纯度直接决定后 续影像提取信息的精度^[19],特别是在图像分 割的基础上进行分类需要高精度的同质区。同 质区的质量需要一定的评价指标。评价指标的 好坏直接影响后续同质区用于扩增训练样本的 可行性。设高光谱影像分割的斑块数目为 n, m_i 表示第 i 个斑块内标记样本的类别众数, S_i 表示第 i 个斑块中标记样本的总数, acc 表示 同质区的纯度,则同质区纯度可用式(3)衡量:

$$acc = \sum_{i=1}^{n} m_i / \sum_{i=1}^{n} S_i$$
 (3)

1.3.2 分类结果评价指标

分类结果的好坏需要一定的衡量标准。本 文的分类结果评价指标为常用的三个指标:总 体分类精度(Overall Accuracy, OA)、平均精 度(Average Accuracy, AA)和 Kappa 系数。计 算OA、AA和Kappa 系数的基础是混淆矩阵。 它是一个衡量分类器分类的准确程度,用于比 较预测类别和真实类别数目的矩阵。矩阵的某 一行数目之和表示该类别地面真实样本数目, 某列之和表示被预测为该类的数量,且主对角 线上的数据代表各类样本被正确分类的数目。 设高光谱遥感影像的类别数为 c,则混淆矩阵 的大小为 c 行 c 列,遥感影像的测试样本的总 个数为 n,混淆矩阵为 M, M_i表示第 j 类被错 分为第 i 类别的样本个数。下面具体介绍这三 种分类评价指标。

1.3.2.1 总体分类精度 OA

OA 是高光谱影像分类正确的测试样本总数占总测试样本数量的百分比。该值越大说明

高光谱影像的分类精度越高,即

$$OA = \sum_{i=1}^{c} M_{ii}/n \tag{4}$$

1.3.2.2 平均精度 AA

AA 为各个类别精度的平均值。该值越大则精度越高,即

$$AA = \left(\sum_{i=1}^{c} (M_{ii} / \sum_{i=1}^{c} M_{ij}))/c\right)$$
(5)

1.3.2.3 Kappa 系数

*Kappa*系数可以定量地评价高光谱分类 图和参考数据一致性的指标。分类结果越好 时,该值越大。它可由式(6)计算得到:

$$Kappa = \frac{n(\sum_{i=1}^{c} M_{ii}) - \sum_{i=1}^{c} (\sum_{i=1}^{c} M_{ij} \sum_{i=1}^{c} M_{ji})}{n^{2} - \sum_{i=1}^{c} (\sum_{i=1}^{c} M_{ij} \sum_{i=1}^{c} M_{ji})}$$
(6)

2 结果与分析

为了验证所提方法的有效性,本文在三种 常见的高光谱数据上分别生成不同尺度同质区 并进行训练样本的扩增,最后进行 SVM 的半 监督分类,并将该方法与其它几种半监督分类 方法进行对比分析。

2.1 实验数据

本文选择 Pavia University、Salinas、Indian Pines 三种常用的高光谱影像数据集进行实验。

2.1.1 Pavia University 数据集

Pavia University 数据简称为 PaviaU 数据, 是由 ROSIS 传感器获得的意大利帕维亚的部 分影像。图像大小为 610×340,共有 42776 个 包含 9 个类别的标记样本。该数据包含 103 个 光谱波段,其空间分辨率为 1.3 m,光谱分辨 率为 4~12 nm。PaviaU 数据的假彩色影像及 地面真实数据如图 4 所示。

2.1.2 Salinas 数据集

Salinas 数据是由 AVIRIS 传感器获得的美 国加利福尼亚州南部山谷的部分图像。图像大 小为 512×217,空间分辨率为 3.7 m。在实验 中一共使用 204 个波段。该数据共有 54129 个 标记样本,包含 16 个类别。三波段的假彩色 合成图像和地面实况图如图 5 所示。



图 5 Salinas 数据

2.1.3 Indian Pines 数据集

Indian Pines 数据简称为 IndianP 数据集, 是由 AVIRIS 传感器获得的美国西部的植被区 域。图像大小为 145×145, 空间分辨率为 20 m,一共包含 224 个波段。实验使用的是剔除 了不能被水反射的 20 个波段后剩下的 200 个 波段。该数据包含 16 个类别的 10249 个标记 样本。其假彩色图和地面真实标记如图 6 所示。

2.2 同质区生成

为得到不同尺度的同质区,本文利用 JSEG分割方法生成大尺度同质区,并采用 SLIC分割方法生成小尺度同质区。

2.2.1 JSEG 同质区生成结果

本文对三种常见的高光谱影像进行传统的 JSEG 分割,并用均值漂移方法对分割结果中 不纯的同质区斑块进行提纯。同时,为了得到 大尺度斑块,对分割结果中过分割的斑块进行 区域合并,最终得到基于 JSEG 的大尺度同质 区结果。

表1列出了对三种高光谱数据进行 JSEG 分割后的同质区纯度和斑块数量。可以看出, 基于 JSEG 分割的大尺度生成方法在三种高光 谱数据上均取得了不错的结果。其中, PaviaU 和 Salinas 数据的分割纯度达到 99%以上,分 辨率较低的 IndianP 数据的精度也达到了 98%

37



图 6 Indian Pines 数据



(a) PaviaU数据





(c) IndianP数据

图 7 JSEG 同质区结果

表1 JSEG 同质区的纯度和斑块数量

数据	PaviaU	Salinas	IndianP
实际斑块数目	2382	889	712
纯度/%	99.72	99.84	98.45

表 2 SLIC 同质区的纯度和斑块数量

数据	PaviaU	Salinas	IndianP
实际斑块数目	4801	2648	1365
纯度/%	99.83	99.79	99.07

以上,说明该方法在高光谱数据上有较好的适 用性和鲁棒性。图 7 所示为 PaviaU、Salinas 和 IndianP 数据的 JSEG 分割结果。可以看出, JSEG 分割获得的斑块内元素数量虽然不均匀, 但分割效果很好。

2.2.2 SLIC 同质区生成结果

为了获得较好的分割结果,需选择合适的 超像素分割个数 K。综合考虑斑块数量以及斑 块纯度,最终本文中 PaviaU、Salinas 和 IndianP数据的分割个数分别选择为 5000、3000 和 1400.

表 2 列出了对三种高光谱数据进行 SLIC 分割后的同质区纯度和实际斑块数目。可以看 出,三种数据的同质区纯度都在 99%以上, 说明 SLIC 分割后同质区斑块的纯度极高。图 8 所示为三种高光谱数据的 SLIC 同质区结果。 可以看出, SLIC 分割获得的斑块数量较多且 面积较小,同质区斑块大小较均匀且有很高的



(a) PaviaU数据

(b) Salinas数据

(c) IndianP数据

图 8 SLIC 同质区结果

表 3 JSEG 同质区扩增训练样本的数量和精	·度
-------------------------	----

数据	数据 初始每类训练样本数目		扩增训练样本精度/%
	5	16662	100
DominII	10	24277	100
	15	30458	99.96
	20	32501	99.96
	5	31354	99.99
Solinoa	10	38167	99.99
Saimas	15	40158	99.99
	20	41218	99.99
	5	3930	97.80
IndianD	10	5217	97.23
mulam	15	6166	97.49
	20	7460	97.52

同质性。SLIC 分割方法在三种高光谱数据上 都得到了较好的同质区分割结果。

2.3 同质区扩增训练样本

利用上面生成的两种不同尺度的同质区扩 增训练样本。对于大尺度同质区,采用K近 邻算法进行样本扩增;对于小尺度同质区,采 用多数投票策略扩增样本。

2.3.1 JSEG 同质区扩增训练样本

JSEG 同质区斑块面积较大且斑块内元素 较多。为了获得较好的扩增样本,利用 K 近 邻算法对 JSEG 同质区扩增训练样本。为了减 小偶然误差的影响,本文的所有实验结果都是 通过随机进行10次实验并取平均值获得的。

表 3 列出了对 PaviaU、Salinas 和 IndianP 数据选择的每类初始训练样本数量为5、10、

15 和 20 时, 采用 K 近邻算法扩增 JSEG 同质 区训练样本的数量和精度。其中,扩增训练样 本的精度通过计算扩增训练样本的预测类别和 真实类别相同的比例来获得。可以看出,通过 JSEG 同质区可对少量的初始训练样本扩增大 量高精度的标记样本点。当每类取 5、10、15 和 20 个样本时, PaviaU 和 Salinas 数据的扩增 样本精度都高于 99%, 分辨率较低的 IndianP 数据的扩增样本精度也高于 97%。虽然利用 JSEG 同质区扩增的样本含有少量错误样本, 但是样本数量却能大量增加。

2.3.2 SLIC 同质区扩增训练样本

与 JSEG 同质区相比, SLIC 同质区的斑块 数量较多且面积较小,因此采用多数投票策略 对其进行样本扩增。表4列出了基于 SLIC 分

衣 4 SLIC 问须区书 瑁训练杆本的数重和精度							
数据	原始每类训练样本数	扩展训练样本数目	扩展训练样本精度/%				
	5	3156	99.93				
Derriel	10	5879	99.51				
1 aviaU	15	8696	99.34				
	10	11083	99.51				
	5	7165	99.87				
Selines	10	13133	99.78				
Saimas	15	17576	99.82				
	10	20830	99.83				
	5	1159	98.80				
IndianP	10	2014	98.83				
	15	2630	99.01				
	20	3239	98.81				

表 5 不同尺度的同质区扩增训练样本的对比

***************************************	初始训练	不同的同质区扩	SLIC 同质区	重复样本类别
双 据 尖 型	样本数目	增样本重复个数	新增样本个数	相同的比率/%
	5	1814	1342	99.50
PaviaL	10	3351	2528	99.47
TaviaO	15	5105	3591	99.32
	20	6791	4292	99.15
	5	4920	2245	99.94
Salinas	10	9395	3738	99.96
Saimas	15	13037	4539	99.97
	20	15627	5203	99.97
	5	735	424	98.07
IndianP	10	1323	691	98.31
mulalli	15	1796	834	98.33
	20	2241	997	98.23

割的小尺度同质区扩增样本的平均数量和精 度。可以看出,采用 SLIC 同质区扩增样本时, PaviaU 和 Salinas 数据的扩增样本精度都在 99%以上,分辨率较低的 IndianP 数据的扩增 样本精度也在 98%以上,说明 SLIC 同质区扩 增的样本精度很高。

表 5 列出了 JSEG 同质区和 SLIC 同质区 扩增样本的对比结果。可以看出, SLIC 同质 区和 JSEG 同质区扩增的样本虽然有重复的部 分,但是 PaviaU 和 Salinas 数据重复部分类别 相同的概率都在 99%以上, IndianP 数据重复 部分的类别一致性在 98% 以上,从侧面说明 了两种方法扩增的样本精度都很高。小尺度同 质区在大尺度同质区扩增样本的基础上新增了 大量的样本,进一步增加了训练样本的数量。

2.4 基于 SVM 的半监督分类

无需参数选择的 SVM 分类具有分类速度 快、效率高等特点。为了证明 JSEG 同质区扩 增训练样本对分类的有效性,采用无需参数选 择的线性 SVM 进行分类,并将其与其它三种 经典的半监督分类方法进行对比。

2.4.1 JSEG 同质区扩增样本对 SVM 分类的 影响

在初始样本确定的情况下,用 JSEG 同质 区扩增的训练样本进行线性 SVM 分类,从而 研究 JSEG 同质区扩增样本对 SVM 分类的影



图 10 小尺度同质区扩增样本前后的 SVM 分类精度对比(OA(%))

响。对于三种常用的高光谱数据,在每类分别 选择 5、10、15、20 个初始样本的情况下,分 别进行 10 次实验并取平均值。

通过图 9 所示的折线图可以直观地看出大 尺度同质区扩增样本前后 SVM 分类精度的对比 情况。采用 JSEG 同质区扩增训练样本后,三 种高光谱数据的 SVM 分类精度都获得了很大幅 度的提升, IndianP 数据分类精度提升最明显。 当每类选择 5 个初始样本时, IndianP 数据的分 类精度提升了 22.24%, Salinas 数据的分类精度 提升了 9.33%, PaviaU 数据的分类精度提升了 18.17%, 说明 JSEG 同质区扩增的训练样本对 SVM 分类提升的效果很好。当每类选择 20 个 初始样本点时, IndianP、Salinas 和 PaviaU 数据 在 JSEG 扩增样本后的 SVM 分类精度分别达到 83.67%、91.86%和 89.08%。

2.4.2 SLIC 同质区新增样本对 SVM 分类的 影响

为了证明 SLIC 同质区扩增训练样本的有效 性,本文对比了仅用 JSEG 同质区扩增样本训 练 SVM 和用 JSEG、SLIC 同质区扩增的训练样 本共同训练 SVM 的分类效果。对于三种高光谱 数据,在每类别分别选择 5、10、15、20 个样本的情况下,进行 10 次实验并计算平均值。

在大尺度同质区扩增样本的基础上,小尺 度同质区新增样本前后的 SVM 分类精度的对比 情况如图 10 所示。小尺度同质区扩增训练样本 后,线性 SVM 的分类精度进一步提升。其中, IndianP 数据的效果最为明显, Salinas 和 PaviaU 数据的分类精度都得到了不同程度的提升。当 每类选择 5 个初始样本时, IndianP、Salinas 和 PaviaU 数据的分类精度分别提升了 1.79%、 1.42%和 0.46%。

2.5 半监督对比实验

为了证明本文方法的有效性,采用其它三种经典的分类方法在三种常见的高光谱数据上进行对比实验。其中,SVM法是基于原始训练样本的支持向量机分类方法;AS-SVM法是指本文的基于不同尺度同质区扩增样本的支持向量机分类方法;CNN-PF法是WeiL等^[20]提出的一种半监督深度网络分类方法,采用新型像素对方法扩大训练集并对影像分类;AGR法是LiuW等^[21]提出的基于锚点建图的半监督分类方法。

丰 6 IndianD 粉根的半股权八米蛙座叶山

2023年5月

衣 0 mulam 数据时十重目为天相反内比								
样本数目		SVM	CNN-PF	AGR	AS-SVM			
	OA	49.73±3.42	55.28 \pm 3.13	42.86 \pm 2.81	74.27 \pm 2.69			
5	AA	61.46±2.61	68.42±3.98	58.87±1.43	83.08 ± 1.78			
	Kappa 系数	0.439 \pm 0.04	0.501 \pm 0.03	0.370 ± 0.03	0.702 \pm 0.04			
	OA	59.78 \pm 2.31	65.43±1.24	47.33±2.44	81.61±2.08			
10	AA	70.02 \pm 1.71	77.29 \pm 1.53	63.11±1.81	89.32±1.09			
	Kappa 系数	0.549 \pm 0.03	0.614 \pm 0.01	0.420 ± 0.03	0.798 ± 0.02			
	OA	62.47±2.41	70.63 \pm 3.27	50.35 \pm 1.29	84.05±1.24			
15	AA	72.79 \pm 1.11	82.35 \pm 3.51	65.21±2.02	91.01 \pm 0.72			
	Kappa 系数	0.577 \pm 0.03	0.669 \pm 0.04	0.451±0.01	0.822 \pm 0.01			
	OA	63.91±2.45	74.68 \pm 2.29	51.72 \pm 2.13	85.25±1.21			
20	AA	76.41±1.63	85.01±1.30	67.08±3.43	92.01 \pm 0.02			
	Kappa 系数	0.596 \pm 0.03	0.715 \pm 0.02	0.467±0.02	0.834 ± 0.01			



图 11 IndianP 数据的半监督分类效果图

表 7 Salinas 数据的半监督分类精度对比

样本数目		SVM	CNN-PF	AGR	AS-SVM
	OA	79.85±2.16	83.69±3.21	74.34 \pm 2.99	90.61 \pm 0.40
5	AA	85.46±1.76	91.01 \pm 1.86	82.13±1.77	95.06 \pm 0.31
	Kappa 系数	0.776 \pm 0.02	0.802 \pm 0.04	0.717 \pm 0.03	0.895 ± 0.01
	OA	83.75±1.29	86.82±1.96	78.04 \pm 2.08	91.85 \pm 0.28
10	AA	89.69 \pm 0.76	92.20±1.45	86.88±1.36	95.76 \pm 0.15
	Kappa 系数	0.820 \pm 0.01	0.843±0.02	0.758 ± 0.02	0.909 ± 0.01
	OA	84.37±0.89	87.79±2.65	80.09 \pm 1.53	92.25 \pm 0.31
15	AA	89.77±0.64	92.91±1.49	88.41±1.13	96.14 \pm 0.20
	Kappa 系数	0.826 \pm 0.01	0.861±0.02	0.780 ± 0.02	0.914 ± 0.01
	OA	84.98±1.19	89.58 \pm 0.85	80.51±1.72	92.41 \pm 0.46
20	AA	90.93 \pm 0.54	94.88±0.21	88.09±1.01	96.27 \pm 0.19
	Kappa 系数	0.833 ± 0.01	0.865 \pm 0.01	0.784±0.02	0.915 ± 0.01

表 6 列出了对 IndianP 数据采用不同方法 所得到的分类精度结果。可以看出,当每类初 始样本数目为 5、10、15 和 20 时,本文的 AS-SVM 方法的精度最高,其次是 CNN-PF 方法, 说明了本文方法的有效性。

图 11 是对 IndianP 数据采用不同的半监督

分类方法所获得的分类效果图。可以看出,采 用 SVM、CNN-PF、AGR 方法所获得的分类 效果图中都有大量明显的噪声,而 AS-SVM 方法的分类效果图中噪声最少且保持了良好的 边缘性。因此,AS-SVM 方法在 IndianP 数据 上的分类效果比其它三种方法更好。



(c) AGR

(d) AS-SVM

图 12 Salinas 数据的半监督分类效果[冬
--------------------------	----------

表 8	PaviaU	数据	的半	监督	分	类	精	度	对	比
-----	--------	----	----	----	---	---	---	---	---	---

样本数目		SVM	CNN-PF	AGR	AS-SVM
	OA	65.89±6.40	71.59 \pm 1.26	51.65 \pm 6.97	81.52±4.27
5	AA	72.66 \pm 3.84	73.09 \pm 2.13	64.53±2.76	85.39±1.88
	Kappa 系数	0.573 ± 0.07	0.641 ± 0.01	0.415 ± 0.06	0.764 \pm 0.04
	OA	70.63 \pm 5.73	73.26 \pm 3.23	52.28±2.29	85.98±3.04
10	AA	77.49 \pm 2.25	78.79 \pm 4.01	67.87±1.17	86.51±1.40
	Kappa 系数	0.631 ± 0.06	0.665 \pm 0.04	0.428±0.02	0.814±0.04
	OA	73.99 \pm 3.56	78.56 \pm 2.84	56.46 \pm 4.11	88.95±1.18
15	AA	80.38±1.24	83.11±3.00	69.93±1.65	88.65 \pm 0.68
	Kappa 系数	1.243 ± 0.67	0.725 \pm 0.03	0.471±0.04	0.851±0.02
	OA	75.16 \pm 3.36	81.32±0.24	56.87±2.98	89.41±1.75
20	AA	81.66±1.30	85.42±1.77	70.45 \pm 0.97	89.08±0.74
	Kappa 系数	0.685 \pm 0.04	0.764 ± 0.01	0.476 ± 0.03	0.862 ± 0.02

表 7 列出了对 Salinas 数据采用 4 种半监 督方法所得到的分类精度结果。可以看出,分 类精度最高的是本文的 AS-SVM 方法,其次 是 CNN-PF 方法, 说明了本文方法对 Salinas 数据分类的有效性。

图 12 是对 Salinas 数据采用不同半监督方 法所获得的分类效果图。可以看出,采用 AS-SVM方法获得的分类图的边缘保持效果最好 且噪声最少,分类效果最好。

表 8 列出了对 PaviaU 数据采用 4 种半监督 分类方法所得到的分类精度结果。可以看出, AS-SVM方法在初始样本数目为5、10、15和 20 时的分类精度都最高。当每类选择 20 个样本 时,AS-SVM方法的分类精度为89.41%,比 SVM 方法高 14.25%, 比 AGR 方法高 32.54%。 图 13 是对 PaviaU 数据采用 4 种半监督方法的 分类效果图。可以看出, SVM、CNN-PF 和 AGR方法所得到的分类图中噪声较多; AS-SVM 方法的分类效果最好,在保持较好边缘性 的同时噪声也较少。图 14 为三种数据的半监督 分类 OA 对比折线图。从图中可以明显看出, 本文方法的分类精度最高。

43





图 14 半监督分类精度对比(OA(%))

3 结束语

本文在同质区的基础上利用极少量的标记 样本扩增出大量高精度的伪标记样本,训练出 预测精度较高的分类模型,从而使得自学习样 本的扩增成为可能。研究结果表明:

(1)对于一个标记点,不同方法的分割过 程可以获得包含此标记点的不一样的同质区, 组合这些同质区可以获取更多的扩增样本点。 实验证明不同的同质区能扩增更多的训练样 本,从而进一步提高分类精度。

(2)大尺度的同质区斑块的纯度相对较低, 采用均值漂移方法对不纯的斑块提纯能显著提 高同质区的纯度。为了减小扩增样本的错误 率,用K近邻方法对大尺度同质区斑块进行 了样本扩增。实验证明该方法在三种数据上都 获得了大量高精度的扩增样本。

(3)用 SVM 分类方法证明了扩增训练样本的有效性。对于三种高光谱数据, AS-SVM 分

类精度远高于仅使用原始标记点的 SVM 分类 精度。与经典的 SVM、CNN-PF、AGR 方法 相比,本文方法的 OA、AA 以及 Kappa 系数 均有不同程度的提高。

然而同质区内的极少数噪声点偶尔会导致 实验失败,因此如何处理噪声点是利用同质区 扩增训练样本过程中的最大难题之一。虽然用 本文方法扩增样本的精度极高,但仍有少量噪 声点,后续将继续致力于减少错误点的扩增。

参考文献

- [1] 赵晋陵,胡磊,严豪,等.联合局部二值模式与
 K-最近邻算法的高光谱图像分类方法 [J]. 红
 外与毫米波学报,2021,40(3):400-412.
- [2] 刘军. 模糊边界特性的灰度图像分割算法研究 [D]. 广州: 广东工业大学, 2011.
- [3] Mehmet S, Buelent S. Survey over image thresholding techniques and quantitative performance e-

valuation [J]. Journal of Electronic Imaging, 2004, **13**(1): 146–168.

- [4] Bellon O R P, Silva L. New improvements to range image segmentation by edge detection [J].
 IEEE Signal Processing Letters, 2002, 9(2): 43-45.
- [5] 王珂,顾行发,余涛,等.结合光谱相似性与相位一致模型的高分辨率遥感图像分割方法[J]. 红外与毫米波学报,2013,32(1):73-79.
- [6] Bargoti S, Underwood J P. Image segmentation for fruit detection and yield estimation in Apple orchards [J]. *Journal of Field Robotics*, 2017, 34 (6): 1039–1060.
- [7] Feng H, Hou B. SAR image despeckling based on local homogeneous-region segmentation by using pixel-relativity measurement [J]. *IEEE Transactions on Geoscience & Remote Sensing*, 2011, 49 (7): 2724–2737.
- [8] Chapel L, Burger T, Courty N, et al. PerTurbo manifold learning algorithm for weakly labeled hyperspectral image classification [J]. IEEE Journal of Selected Topics in Applied Earth Observations & Remote Sensing, 2014, 7 (4): 1070– 1078.
- [9] Bruzzone L, Persello C. A novel context-sensitive semisupervised SVM classifier robust to mislabeled training samples [J]. *IEEE Transactions on Geoscience & Remote Sensing*, 2009, **47**(7): 2142– 2154.
- [10] Tan K, Zhou S, Du Q. Semisupervised discriminant analysis for hyperspectral imagery with blocksparse graph [J]. *IEEE Geoscience& Remote Sensing Letters*, 2015, **12**(8): 1765–1769.
- [11] Zhou Z H, Li M. Semi-supervised learning by disagreement [J]. Knowledge & Information Systems, 2010, 24(3): 415-439.
- [12] Cui B, Xie X, Hao S, et al. Semi-supervised classification of hyperspectral images based on extend-

ed label propagation and rolling guidance filtering [J]. *Remote Sensing*, 2018, **10**(4): 515.

- [13] Amini S, Homayouni S, Safari A. Semi-supervised classification of hyperspectral image using random forest algorithm [C]. Quebec: IEEE Geoscience and Remote Sensing Symposium, 2014.
- [14] 周绍光,吴昊,赵婵娟,等.利用同质区特性的 高光谱图像迁移学习分类[J].计算机工程与 应用,2021,57(21):224-233.
- [15] Geng Y, Chen J, Wang L. A novel color image segmentation algorithm based on JSEG and Normalized Cuts [C]. Hangzhou: 6th International Congress on Image and Signal Processing, 2013.
- [16] 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.
- [17] 黄亮,姚丙秀,陈朋弟,等.融合层次聚类的高 分辨率遥感影像超像素分割方法[J]. 红外与 毫米波学报,2020,39(2):263-272.
- [18] Comaniciu D, Meer P. Mean shift analysis and applications [C]. Kerkyra: 7th IEEE International Conference on Computer Vision, 1999.
- [19] Clinton N, Holt A, Scarborough J, et al. Accuracy assessment measures for object-based image segmentation goodness [J]. *Photogrammetric Engineering & Remote Sensing*, 2010, **76**(3): 289–299.
- [20] Li W, Wu G D, Zhang F. Hyperspectral image c Photogrammetric Engineering & Remote Sensing classification using deep pixel-pair features [J]. *IEEE Transactions on Geoscience & Remote Sensing*, 2017, 55(2): 844-853.
- [21] Liu W, He J, Chang S F. Large graph construction for scalable semi-supervised learning [C]. Haifa: 27th International Conference on Machine Learning, 2010.