

引用格式: Shao Wenjing, Sun Weiwei, Yang Gang. Comparison of Texture Feature Extraction Methods for Hyperspectral Imagery Classification[J]. Remote Sensing Technology and Application, 2021, 36(2): 431-440. [邵文静, 孙伟伟, 杨刚. 高光谱遥感影像纹理特征提取的对比分析[J]. 遥感技术与应用, 2021, 36(2): 431-440.]
doi: 10.11873/j.issn.1004-0323.2021.2.0431

高光谱遥感影像纹理特征提取的对比分析

邵文静, 孙伟伟, 杨 刚

(宁波大学地理与空间信息技术系, 浙江 宁波 315211)

摘要: 地物的“同物异谱”或“异物同谱”问题, 使得仅仅依据高光谱影像的光谱信息较难得到理想的分类精度。纹理特征是地物空间分布的重要结构信息, 能够一定程度上弥补光谱特征在高光谱遥感影像分类中的不足。纹理特征提取在高光谱遥感影像分类中得到了诸多发展, 然而当前的纹理特征方法缺乏较为全面的对比分析。因此, 选取旋转不变局部二值模式、简单线性迭代、扩展形态剖面、差分形态剖面、属性剖面、3D-Gabor、联合双边滤波和导向滤波共8种典型的纹理特征方法, 利用印第安纳、帕维亚大学和雄安3个高光谱数据集设计分类实验, 采用分类精度、计算时间、总体分类精度的标准差来进行定量评价。实验结果表明: 扩展形态剖面的总体分类精度和计算速度整体上优于其他7种方法。

关键词: 高光谱遥感; 纹理; 分类; 特征提取

中图分类号: TP75 **文献标志码:** A **文章编号:** 1004-0323(2021)02-0431-10

1 引言

高光谱遥感技术具有光谱通道窄、光谱分辨率高的优势, 能够用以区分不同亚类地物的细微光谱差异, 在精细分类和定量反演方面具有更大的应用潜力^[1]。高光谱影像分类是利用地物的不同光谱响应特性, 构建分类模型如SVM(Support Vector Machine)、RF(Random Forest)、ELM(Extreme Learning Machine)等来识别不同地物。

纵使高光谱遥感存在诸多优势, 然而光谱数据维数高、波段冗余等问题不仅增加了处理数据的成本, 也影响了地物分类精度^[2]。对此国内外专家学者提出了各种波段选择^[3-5]和特征提取^[6-7]的方法来解决这一问题^[2]。其中纹理特征是二维光谱信息到低维空间的投影, 通过度量像素点及其周围空间邻域的差异, 能够有效区分不同地物, 对于解决高光

谱分类中遇到的“同物异谱”或“异物同谱”问题有很好的辅助作用。

纹理特征提取方法可分为4种: 数学变换法、模型法、统计法和结构分析法^[8]。数学变换法是将频率域特征映射到空间域来提取影像的纹理特征, 例如Gabor滤波能够提取影像不同方向上的频率信息; 考虑到高光谱遥感的光谱维特点, Bau等^[9]对Gabor滤波进行改进提出了3D-Gabor滤波; 边缘保持滤波^[10]通过提取边缘信息强化分类效果, 并在此基础上发展出了基于光谱维特征提取的边缘保持滤波用于提取空谱域特征^[11]。模型法认为像素间存在某种相互关系, 通过设定不同的模型参数来定义不同的纹理: Solberg等^[12]首次将马尔科夫随机场(Markov Random Field, MRF)用于遥感分类中, 此后无向图模型(Undirected Graph Model, UGM)被广泛用于遥感图像^[13-14]; 随后, 基于条件独立假设的

收稿日期: 2019-12-12; 修订日期: 2021-02-03

基金项目: 国家自然科学基金项目(41971296、41671342、41801256、61871177), 浙江省自然科学基金项目(LR1901D0001、LQ18D010001), 武汉大学测绘遥感信息工程国家重点实验室开放基金(18R05)。

作者简介: 邵文静(1996—), 女, 湖北江陵人, 硕士研究生, 主要从事高光谱分类研究。E-mail: 1811073014@nbu.edu.cn

通讯作者: 孙伟伟(1985—), 男, 河南巩义人, 博士, 副教授, 主要从事地理信息系统和遥感理论与方法及“3S”技术在海岸带资源管理与环境变化监测中的应用研究。E-mail: sunweiwei@nbu.edu.cn

条件随机场 (Conditional Random Field, CRF) 也应应用到了遥感分类领域^[15]。统计法对纹理的数字特征进行提取,以灰度共生矩阵和局部二值模式为代表:局部二值模式通过度量中心像素与周围像素的差异提取局域纹理特征;为解决二值模式过多以及旋转不变的问题,出现了统一局部二值模式、旋转不变局部二值模式以及统一旋转不变二值模式。结构法描述纹理基元及其排列规则,例如简单线性迭代^[16]根据局域像素间的相似性进行聚类;扩展形态剖面^[17]通过形态学操作减少噪声;后来在EMP的基础上提出了差分形态剖面,以记录影像对于元素尺寸的响应程度;鉴于EMP和DMP无法对影像的属性进行度量,发展出了属性剖面^[18]和消光剖面^[19],通过度量影像的不同属性进行特征提取;为了弥补AP难以识别不同场景中同类地物的缺陷,提出了不变属性剖面 (Invariant Attribute Profiles, IAPs) 的方法,从高光谱图像的局部提取空间和频率域的不变特征^[20]。当前,深度学习等方法也成为了遥感影像分类的热点,多同纹理特征相结合应用到高光谱纹分类上^[21],例如将超像素特征和扩展多属性轮廓嵌入到一个多核学习框架中,同时利用空间维度和光谱维度的局部和多尺度信息进行高光谱图像分类^[22];在深度学习与主动学习的框架中利用马尔可夫随机场也能进一步提高分类性能^[23];此外,不同纹理特征之间相结合的方法对于提高分类精度也有着显著作用^[21, 24]。

上述工作推进了高光谱遥感的纹理特征研究。然而,当前关于高光谱纹理特征大多针对个别方法设计的对比实验,缺少对当前方法的统一对比,不利于纹理特征在高光谱领域的进一步应用。因此,本文综合分析当前的纹理特征提取研究工作,选取8种最为典型的纹理特征提取方法,利用3个高光谱影像数据集来设计分类实验,探讨不同纹理特征提取方法的优缺点及适用性,旨在为纹理特征用于高光谱遥感影像分类的实际应用提供借鉴和科学参考。

2 纹理特征提取方法

本文从数学变换法、统计法和结构分析法3大类中选取8种典型的纹理特征方法来进一步分析。模型法由于建模时间长,且对于数量少的类别无法进行建模^[25],不利于分类结果比较,因此不在此次试验考虑范围之内。

2.1 统计法

统计法以局部二值模式 (Local Binary Pattern, LBP) 最为典型。在半径为 R 的邻域内, LBP 首先比较中心像元与各个邻域像元的灰度值,通过二值化表达 (公式(2)) 来替代对应的灰度值。在此基础上,通过二值的加权求和得到局部的二值模式;最后,用统计频数直方图来表征 LBP 纹理特征,其公式如下:

$$\text{LBP}_{P,R} = \sum_{p=0}^{P-1} s(g_p - g_c) 2^p \quad (1)$$

$$s(x) = \begin{cases} 1, x \geq 0 \\ 0, x < 0 \end{cases} \quad (2)$$

其中: $\text{LBP}_{P,R}$ 为局部二值模式; R 为半径大小; P 为邻域像元的数量; g_p 为邻域像元的灰度值; g_c 为中心像元的灰度值; $s(x)$ 为灰度的二值化表达。

后来,学者们提出 riLBP (rotation invariant Local Binary Pattern), 利用公式(3)的二值模式以提升 LBP 的纹理表征性能^[26]。riLBP 公式如下:

$$\text{LBP}_{P,R}^{\text{ri}} = \min(\text{ROR}(\text{LBP}_{P,R}, i), \quad (3)$$

$$i = 0, 1, \dots, P-1)$$

其中: $\text{LBP}_{P,R}^{\text{ri}}$ 为旋转局部二值; $\text{ROR}(x, i)$ 为将十进制数 x 对应的二进制序列循环右移 i 位。

2.2 结构法

2.2.1 简单线性迭代 SLIC (Simple Linear Iterative Clustering)

SLIC 是一种典型的迭代方法,从 K 均值聚类改进而来,具有简单高效、边缘一致性好的优点^[27]。SLIC 最初为彩色影像分割而提出,像素 lab 色彩 (l 表示色彩亮度, a 表示绿色到红色分量, b 表示蓝色到黄色分量) 与其空间位置 (x, y) 共同构成一个 5 维向量。对于影像 I 设定规则化系数 m 与超像素个数 S ; 根据像素之间的相似性对像素进行聚类; 最后迭代至聚类中心不变或满足迭代条件即完成影像分割。相似度计算公式如下:

$$d_{lab} = \sqrt{(I_k - I_i)^2 + (a_k - a_i)^2 + (b_k - b_i)^2} \quad (6)$$

$$d_{xy} = \sqrt{(x_j - x_i)^2 + (y_j - y_i)^2} \quad (7)$$

$$D_s = d_{lab} + \frac{m}{S} d_{xy} \quad (8)$$

其中: d_{lab} 表示第 k 个聚类中心 (超像素的像素中心) 与第 i 个像素之间的颜色距离; d_{xy} 表示第 k 个聚类中心与第 i 个像素之间的空间距离; D_s 衡量像素之间的相似度, 值越小, 相似度越强; m 为规则化系数; S 为超像素数量。SLIC 能够整合影像的空间信息和

光谱信息,利用超像素内的像素均值^[16]或像素内特征^[27]来进行分类。

2.2.2 形态学剖面(Morphological Profiles, MP)

形态学是用于分析空间结构的理论,基本运算是膨胀和侵蚀,开操作和闭操作是常用的两个操作^[18]。

(1)扩展形态学剖面 EMP (Extend Morphological Profiles)

在高光谱遥感领域,形态学剖面最初用于经主成分分析 PCA (Principal Component Analysis) 后的第一主成分影像。后来,文献^[17]将第一主成分扩展到多个主成分,被称作扩展形态剖面 EMP。EMP 的开操作与闭操作的公式如(9-10)所示:

$$MP_{\gamma} = \{ MP_{\gamma}^k(I) = \gamma^k(I), \forall k \in [0, n] \} \quad (9)$$

$$MP_{\phi} = \{ MP_{\phi}^k(I) = \phi^k(I), \forall k \in [0, n] \} \quad (10)$$

其中: MP_{γ} 表示经过开变换的影像; MP_{ϕ} 表示经过闭变换的影像; $\gamma^k(I)$ 和 $\phi^k(I)$ 分别表示对影像 I 进行的开操作和闭操作; k 为结构元素大小,当 $k=0$ 时,表示未对原始图像进行操作。

(2)差分形态剖面 DMP (Differential Morphological Profile)

DMP 是在 EMP 的基础上进行差分操作。DMP 通过测定相邻大小的元素结构的坡度,即相邻大小结构元素处理后的影像取差。DMP 的开操作和闭操作的公式^[28]如下:

$$DMP_{\gamma} = \{ DMP_{\gamma}^k \} = \{ |MP_{\gamma}^k - MP_{\gamma}^{k-1}|, \quad (11) \\ k \in [1, n] \}$$

$$DMP_{\phi} = \{ DMP_{\phi}^k \} = \{ |MP_{\phi}^k - MP_{\phi}^{k-1}|, \quad (12) \\ k \in [1, n] \}$$

其中: DMP_{γ}^k 是经过开操作的形态剖面; DMP_{ϕ}^k 表示经过闭操作的形态剖面; k 为结构元素大小,当 $k=0$ 时,表示未对原始图像进行操作。

(3)属性形态剖面 AP (Attribute Profiles)

AP 针对 EMP 和 DMP 不能很好地提取影像的集合特征而提出。AP 将灰度影像看作多个二值图像的叠加,依照二值图像的形式划分连通域,计算连通域的相应属性,大于阈值的区域被保留,小于阈值则归为相邻区域的灰度值。如果邻域灰度值较低,称为变薄;反之,则称为变厚。常用的属性有与区域形状相关的属性,如面积等;或与灰度变化有关的属性,如标准差等^[29]。AP 公式如下^[30]:

$$AP(f) = \prod_i \left\langle \begin{matrix} \prod_{i'} \prod_{\phi_{i'}^{\lambda} = (n-1+i), \forall i' \in [1, n]} \\ \prod_{i'} \prod_{\phi_{i'}^{\lambda} = (i-n-1), \forall i' \in [n+1, 2n+1]} \end{matrix} \right\rangle \quad (13)$$

其中: f 代表主成分影像, \prod_{ϕ^r} 为变薄操作; \prod_{ϕ^r} 为变厚操作, T' 表示一系列递增的属性阈值, $T' = \{T_1, T_2, \dots, T_n\}$ 。对于 $T_i, T_j \in T'$ ($i \leq j$), 有 $T_i \subseteq T_j$; i 表示属性图层, λ 表示属性阈值。

2.3 数学变换法

2.3.1 3D-Gabor

Gabor 滤波引入视觉神经感知理念来处理图像,能够捕捉到影像特定的范围和方向信息^[31]。考虑到高光谱影像的数据立方体特性,文献^[9]提出了 3D-Gabor 滤波。3D-Gabor 能从空谱域获取特定方向尺度及频率信息,具有旋转不变性。

3D-Gabor 滤波器是由高斯包络调制的正弦函数。滤波的实部对纹理敏感,因此保留实部调制的高斯核作为滤波器。公式如下^[31]

$$g(\chi, \gamma, z) = a(\chi, \gamma, z) \times c(\chi, \gamma, z) \quad (14)$$

$$a(\chi, \gamma, z) = \frac{1}{(2\pi)^{\frac{3}{2}} \sigma^3} e^{-\frac{1}{2\sigma^2}(x^2 + y^2 + z^2)} \quad (15)$$

$$c(\chi, \gamma, z) = \cos(2\pi(F_x x + F_y y + F_z z)) \quad (16)$$

其中: $g(\chi, \gamma, z)$ 为 3D-Gabor 滤波; χ, γ 表示以中心像素为基准的空间维坐标; z 表示光谱维坐标; $a(\chi, \gamma, z)$ 为 3D-Gabor 高斯核部分; $c(\chi, \gamma, z)$ 为正弦分量余弦部分; 标准差 σ 描述在空间和光谱轴中高斯包络的大小规模; (F_x, F_y, F_z) 表示中心频率,具体公式可参考文献^[9, 31]。

2.3.2 边缘保持滤波 EPF (Edge Preserving Filter)

EPF 利用影像空间灰度变化来减少图像噪声并保持边缘信息^[32]。常用的边缘保持滤波有双边滤波、导向滤波等^[32-33]。导向滤波和双边联合滤波利用 PCA 变换后的第 1 或前 3 个主成分作为引导图像,在分类结果的基础上进行滤波^[10]。

(1)联合双边滤波 JBF (Joint Binary Filter)

联合双边滤波综合考虑基于高斯分布的空间权重和像素间的辐射差异,并用引导图像加以约束,实现弱化噪声、强化边缘的目的。公式如下:

$$O_i = \frac{1}{k_i^b} \sum_{j \in w_i} G_{\delta_r}(\|i-j\|) G_{\delta_s}(I_i - I_j) P_j \quad (17)$$

$$K_i^b = \sum_{j \in w_i} G_{\delta_s}(\|i-j\|) G_{\delta_s}(|I_i - I_j|) \quad (18)$$

其中: O_i 为滤波的结果; K_i^b 为权重系数; P_j 为窗口的中心像素; G_{δ_r} 表示空间域像素的权重; G_{δ_s} 为光谱域权重; $\|i-j\|$ 表示影像的空间距离; I_i 和 I_j 表示像素 i 和 j 的像素灰度, $|I_i - I_j|$ 为像素灰度差取绝对值。当

像素灰度差异小, $1/K_i^b$ 接近 1, 输出像素 O_i 为原始图像的空间平滑结果, 反之有边缘保持的效果。具体参见文献[10]。

(2) 导向滤波 GF (Guided Filter)

导向滤波 GF 假设输入和输出像素灰度之间线性相关, 对灰度变化较大的区域能够有强化作用, 对于非边缘的内部区域产生平滑的效果, 因此有边缘保持的效果。GF 的计算公式如下^[10]:

$$O_i = a_j I_j + b_j, \forall i \in w_j \quad (21)$$

$$E(a_j, b_j) = \sum_{i \in w_j} (a_j I_j + b_j - P_i)^2 + \epsilon a_j^2 \quad (22)$$

其中: I_j 为引导图像 I 的第 j 个像素; O_i 为滤波后的结果; a 和 b 为待求参数; w 为窗口大小。公式(22)为公式(21)的求解函数, 其中 P_i 为输入像素, ϵ 表示正则化参数。

3 实验与分析

实验选取印第安纳数据集、帕维亚大学数据集和雄安数据集等 3 个高光谱影像集来设计分类实验。对比的 8 种方法包括 riLBP、SLIC、EMP、DMP、AP、3D-Gabor、JBF 和 GF。实验使用支持向量机 (Support Vector Machine, SVM) 作为分类器。实验采用总体精度 (Overall Accuracy, OA)、平均精度 (Average Accuracy, AA)、总体分类精度的标准差 (Standard Deviation, SD)、计算时间 (Time)、Kappa 系数 (Kappa Coefficient, KC) 共 5 个评价指标。OA、AA 和 KC 评价分类精度, 计算时间计量不同方法的计算效率。

3.1 实验数据

印第安纳数据集 (http://www.ehu.eus/ccwint-co/index.php/Hyperspectral_Remote_Sensing_Scenes): 由 AVIRIS 传感器在美国印第安纳州西北部的印第安纳松树试验场采集。影像大小为 145×145 (图 1), 空间分辨率为 20 m, 波长范围为 $0.4 \sim 2.5 \mu\text{m}$; 原始数据共 224 个波段, 剔除 24 个水汽吸收严重的波段后保留 200 个波段。地物类型共 16 类, 以农作物为主。地物形状规整, 呈几何块状分布。

帕维亚大学数据集 (http://www.ehu.eus/ccwintco/index.php/Hyperspectral_Remote_Sensing_Scenes): 由 ROSIS-03 传感器在意大利 Pavia 大学获取 (图 2); 数据包含 610×340 像素, 空间分辨率为 1.3 m, 波谱范围为 $0.43 \sim 0.86 \mu\text{m}$; 共 120 个波段, 去除 12 个噪声波段, 剩余 103 个波段, 数据共 9 类地物, 以人工地物为主。大部分地物斑块细碎, 较少存在规则的

几何形态。

雄安数据集 (http://www.hrs-cas.com/a/share/shujuchanpin/2019/0501/1049.html?tdsourcetag=s_pctim_aiomsg): 为航空高光谱图像, 采用高分专项成像光谱仪采集雄安地区数据 (图 3), 由中国科学院空天信息研究院实地调研地物分布而制成的数据集。影像的光谱范围为 $0.4 \sim 1 \mu\text{m}$, 250 个波段, 空间分辨率为 0.5 m。从原始影像中截取 900×900 个像元的部分影像。影像包含 14 类主要地物, 以自然地物为主, 包括各类灌木乔木及农作物。地物形状规整, 主要呈方形块状分布。




图 1 印第安纳数据

Fig.1 The image of Indian Pines



图 2 帕维亚大学数据

Fig.2 The image of Pavia University




图 3 雄安数据

Fig.3 The image of Xiong'an

3.2 参数设置

为降低计算量,实验使用PCA对所有的数据集进行处理,选用前10个PCA图层来进行实验分析。印第安纳数据中随机选取10%作为训练样本,帕维亚大学中随机选取1%作为训练样本,雄安数据集选取0.5%作为训练样本,其余用作测试样本。实验参数在参考已有文献的基础上结合具体实验结果选取最佳参数。每一组实验运行10次,取平均值作为实验结果。

riLBP主要包括邻域像元的数量(P)、半径大小(R)、直方图窗口 $2n+1$ 等3个参数。参考文献[34],实验参数选取 $P=8, R=2$;印第安纳、帕维亚大学数据和雄安数据中 n 分别设置为8、10和12。

SLIC主要参数有规则化系数(m)和超像素大小(S)。参考文献[16],印第安纳数据集 $S=5, m=0.01$;帕维亚大学数据集 $S=7, m=1.5$;雄安数据集 $S=12, m=1.5$ 。

EMP参数主要有结构元素(SE)和结构元素的大小(k)。结构元素的大小是一系列递增的参数。参考文献[17]、[28],EMP的SE统一选取为disk。印第安纳数据参数选取 $k=[4, 7, 10, 13, 16, 19, 22, 25]$;帕维亚大学数据中 $k=[3, 6, 9, 12, 15, 18, 21, 24]$;雄安数据参数选取 $k=[3, 7, 11, 15, 19, 23, 27, 31]$ 。考虑到选择不同的SE及属性会导致EMP、DMP和AP的计算时间存在误差,本文采用不同SE或属性均值特征的计算时间均值。

DMP采用与EMP相同数量的结构元素尺寸。印第安纳数据集中 $SE=disk, k=[2, 5, 8, 11, 14, 17, 20, 23]$;帕维亚大学数据集中 $SE=sphere, k=[2, 6, 10, 14, 18, 22, 26, 30]$;雄安数据集中选取 $SE=disk, k=[3, 7, 11, 15, 19, 23, 27, 31]$ 。

AP包括属性和属性阈值(λ)两个参数。由于AP的属性阈值是由一系列递增的参数决定。本文参照文献[30],调整属性阈值为8个,以确保AP与EMP、DMP实验具有可对比性。印第安纳选择面积(area)属性, $\lambda=[49, 169, 361, 625, 961, 1369, 1849, 2401]$;帕维亚大学中选择标准差属性, $\lambda=[0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8]$;雄安数据集中选择标准差属性(std), $\lambda=[5, 10, 15, 20, 25, 30, 35, 40]$ 。

3D-Gabor的参数主要有窗口大小(W)、滤波方向(Φ, θ)和滤波频率(F)。参考文献[31],本文设置 $\varphi=[0, \pi/4, \pi/2, -\pi/2, -\pi/4], \theta=[0, \pi/4, \pi/2, -\pi/$

$2, -\pi/4], F=[1/2, 1, 4, 1/6, 1/8]$ 。印第安纳数据 $W=11$;帕维亚大学数据中 $W=7$;雄安数据中 $W=7$ 。

JBF的参数主要包括空间维权重(δ_s)和光谱维权重(δ_r)构成。参考文献[10],设置印第安纳数据参数为 $G_s=3, G_r=0.01$;帕维亚大学数据集 $G_s=4, G_r=0.2$;雄安数据集 $G_s=6, G_r=0.15$ 。

GF参数包括空间权重(w)和误差系数参数(ϵ)。参考文献[10];印第安纳数据集设置为 $w=3, \epsilon=0.1$;帕维亚大学设置为 $w=5, \epsilon=0.2$;雄安数据集 $w=7, \epsilon=10$ 。

最终实验结果参见表1~4。表1~4中的SVM列表示前10个PCA图层的分类结果。

3.3 实验结果分析

印第安纳数据集的分类精度由高到低分别为:riLBP>EMP>DMP>AP>SLIC>JBF>GF>3D-Gabor。前三者总体分类精度相对于原始影像分别提高29.32%、29.22%和28.98%,后三者相对于原始影像的分类精度分别提高5.18%、16.53%和18.37%。riLBP通过度量中心像素与周围像素之间的差异区分地物,并且具有旋转不变性,能很好地识别不同地物。EMP通过形态学变换很大程度上消除了地物内部易错分的图斑。DMP进行差分操作的过程中受到随机性影响引入了新的图斑,导致总体分类精度有所下降。但对于元素结构响应较高的地物类别DMP优于EMP。AP和SLIC总体分类精度相差不大。AP对于属性差异不大的类别(如苜蓿和牧草在面积差异不大)分类精度低于EMP和DMP。SLIC的分类精度取决于分割边界与地物边界的吻合程度,因此SLIC的错分主要发生在相邻地物类别上(图4中可以看出)。JBF和GF总体分类精度不理想,但部分类别(如钢铁塔、草树混合地和大豆疏耕地精度较高)。

这是因为GF和JBF都在SVM原始分类的基础上进行,受到空间权重的影响,对原始分类精度较高的类别精度会进一步提升,反之会下降。3D-Gabor缺乏细致的纹理特征,因此分类效果并不理想。

帕维亚大学数据集分类图见图5,其中分类精度由高到底分别为:AP>EMP>DMP>SLIC>GF>JBF>riLBP>3D-Gabor。AP、EMP和DMP相较于原始精度分别提高了15.06%、15.03%、12.9%。后三者相对于原始影像分别提高了

表 1 印第安纳数据的分类精度(单位: %)

Table 1 Classification accuracy of Indian Pines data(Unit: %)

地物类别	纹理特征提取方法/%								
	riLBP	SLIC	EMP	DMP	AP	3D-Gabor	JBF	GF	SVM
苜蓿	95.12	84.88	97.56	98.54	94.02	29.02	62.44	29.76	28.78
玉米未耕地	98.39	91.46	97.32	96.76	95.98	62.37	82.11	79.81	55.83
玉米疏耕地	98.84	92.64	98.53	98.26	97.07	60.13	64.31	63.27	47.20
玉米	98.75	82.82	96.90	99.06	94.38	49.30	84.84	63.99	31.46
牧草地	98.01	93.68	98.21	97.20	96.77	87.38	93.56	94.16	83.52
草树混合地	99.34	97.63	99.88	99.48	99.08	98.22	100.00	100.00	90.91
修剪的牧草	93.33	95.27	99.20	97.60	96.53	74.00	94.00	96.00	56.80
干牧草	99.84	98.51	100.00	100.00	99.59	97.56	100.00	100.00	93.93
燕麦	98.15	77.22	100.00	100.00	93.84	26.67	8.33	1.11	26.67
大豆未耕地	98.74	92.94	97.92	97.53	96.78	62.82	86.13	76.46	58.49
大豆疏耕地	99.37	95.45	99.61	99.33	98.44	78.37	95.27	95.50	78.79
大豆已耕地	98.00	84.10	98.13	97.45	94.42	47.75	72.90	68.16	40.37
小麦	100.00	93.48	99.13	99.46	98.02	96.52	100.00	99.89	93.04
树木	99.85	98.32	100.00	99.98	99.54	95.40	99.89	99.93	94.39
林间小道	99.14	91.87	100.00	99.83	97.71	55.88	60.72	68.27	32.02
钢铁塔	94.84	89.17	96.43	100.00	95.11	86.55	93.81	99.64	80.12
OA	98.98	94.02	98.88	98.64	94.23	74.84	88.03	86.23	69.66
AA	98.11	91.54	98.68	98.78	96.70	69.25	81.14	77.25	62.02
KC	98.83	93.17	98.72	98.45	93.42	71.12	69.70	65.26	65.08

表 2 帕维亚大学分类精度(单位: %)

Table 2 Classification accuracy of Pavia University data(Unit: %)

地物类别	纹理特征提取方法/%								
	riLBP	SLIC	EMP	DMP	AP	3D-Gabor	JBF	GF	SVM
柏油路	91.45	95.24	96.63	92.18	97.96	91.18	97.82	96.73	88.69
草地	99.25	99.51	99.85	99.45	99.68	95.92	99.81	100	96.05
沙砾	94.63	77.31	98.44	88.47	94.52	64.99	73.63	65.42	47.16
树木	60.16	90.51	97.30	95.30	93.81	90.35	89.84	83.68	75.35
金属板	93.18	98.35	99.86	96.53	98.63	98.65	100	100	99.78
裸地	98.69	99.16	99.93	98.43	98.49	74.85	79.15	71.67	53.72
沥青屋顶	87.56	90.87	95.08	94.76	99.71	71.16	75.63	77.71	59.18
地砖	95.41	88.37	95.06	92.76	98.01	83.26	97.78	98.44	79.34
阴影	45.18	90.30	89.91	82.03	96.65	95.48	98.62	99.77	80.91
OA	92.87	95.60	98.33	96.20	98.36	89.01	92.88	93.04	83.30
AA	85.06	92.18	96.90	93.32	97.50	85.09	90.25	88.16	75.76
KC	90.49	94.16	97.78	94.94	97.82	85.31	81.55	80.77	77.45

9.74%、9.73%、5.71% 的精度。帕维亚大学以人工地物为主,属性差异明显,因此 AP 能取得较好的精度,地砖、柏油路和沥青屋顶等人工地物的分类精度高于其他方法。EMP 通过形态学操作消除了地物内部图斑,分类精度也较高。SLIC 只能设定固定尺寸大小和规则化系数,而帕维亚大学不同地块差异明显(小到仅占几个像素,大到占地几百个像素),并且形态各异(从方形到圆形,形态差异巨大),分割结果不能很好地贴合地物分布边界,效果并不理想。riLBP 总体分类精度不高,这是由同一地物内部纹理差异较大(如树木,沙砾和阴影)造

成。GBF 总体分类精度不高,然而在地物边界清晰、内部纹理平滑的类别如草地和金属板,能够达到很好的分类精度。

雄安数据集分类图见图 6,总体分类精度和 Kappa 系数由高到底分别为 EMP>riLBP>SLIC>DMP/AP>JBF>GF>3D-Gabor。雄安数据集中地物形状规则,影像分割能够达到较好的效果,因此 SLIC 能达到较高精度。JBF 和 GF 总体分类精度较低,但二者对于地物的分类精度存在较大差异:一是由于原始 SVM 分类精度本身存在较大差异(如水域精度高达 94.71%,稀疏林精度仅有

表 3 雄安分类精度(单位:%)

Table 3 Classification accuracy of Xiong'an data(Unit: %)

地物类别	纹理特征提取方法								
	riLBP	SLIC	EMP	DMP	AP	3D-Gabor	JBF	GF	SVM
复叶槭	97.76	98.59	99.54	96.86	97.79	91.72	95.33	96.19	89.34
柳树	93.78	97.46	99.90	95.27	98.83	79.65	63.49	61.11	75.31
房屋	97.43	98.80	98.47	96.74	96.65	95.19	96.59	97.08	92.93
桃树	94.17	95.31	97.13	86.78	88.81	72.97	84.24	84.58	68.11
国槐	95.68	97.16	98.92	93.84	95.66	87.17	90.98	92.29	85.33
白腊梅	98.86	98.75	99.53	98.63	99.17	95.66	99.38	99.84	93.98
草地	89.82	82.24	92.79	81.84	76.39	64.61	56.51	53.17	55.55
水域	99.08	98.52	99.31	97.39	97.96	95.36	99.19	99.92	94.71
稀疏林	92.00	81.31	69.93	47.83	27.17	14.23	0.00	0.00	17.10
菜地	92.97	83.87	93.95	86.91	81.05	36.37	5.28	3.15	34.02
杨树	97.44	96.48	96.78	90.22	95.04	86.68	95.38	96.57	82.87
玉米	96.20	94.49	98.64	94.97	94.23	79.03	93.22	94.08	73.82
梨树	97.79	96.82	99.01	96.18	94.06	85.24	86.26	86.64	82.99
大豆	66.38	85.25	93.46	80.59	80.74	71.50	98.39	98.12	60.38
OA	97.84	96.72	98.53	94.72	94.72	86.41	89.90	89.77	83.76
AA	93.52	93.22	95.53	88.86	87.40	75.38	76.02	75.91	71.89
KC	94.21	96.18	98.29	93.83	93.85	84.16	76.32	76.25	81.07

表 4 不同方法的计算时间对比(单位:s)

Tabale4 Computational time of different methods(Unit:s)

	riLBP	SLIC	EMP	DMP	AP	3D-Gabor	JBF	GF
印第安纳	364.20	225.33	66.32	66.66	357.48	149.320	0.21	0.15
帕维亚大学	5 351.0	267.22	100.18	103.21	2 039.1	1 366.00	2.08	0.48
雄安	14 798.6	3 020.59	321.98	328.46	7 913.02	595.02	4.24	3.25




图 4 印第安纳数据分类图

Fig.4 Classification maps of Indian Pines data

17.1%);二是由于提取出的边缘信息与地物分布的边界在一些类别上并不具有很好的一致性。此外,影像中存在一定面积的阴影,对边缘信息的提取也产生了一定误导。

表 4 为不同方法的计算时间对比,计算时间排

序依次为:riLBP>AP>SLIC>3D-Gabor>EMP>DMP>JBF>GF。计算时间最短的是 GF 和 JBF,二者作为图像后处理的方法只需要对分类图进行操作,处理的图像维度小,因此耗时最短。EMP 的形态学操作过程简单,耗时较短。SLIC 的




图 5 帕维亚大学数据分类图
Fig.5 Classification maps of Pavia University data




图 6 雄安分类图
Fig.6 Classification maps of Xiong'an data

计算时间与分割数量有关,超像素数量越多,计算时间越长。DMP是在EMP的基础上进行的,时间稍长于EMP。虽然3D-Gabor精度较低,但是计算时间也较短。riLBP不仅要计算局部灰度差异,还要对其进行特征统计,因此耗时最长。

4 结 论

本文选取当前典型的8种纹理特征提取方法,利用印第安纳数据集、帕维亚大学数据集和雄安数

据集来分析不同方法的分类性能。实验结果表明,EMP的分类精度和计算速度在各种方法中表现最优。但EMP对像素进行无差别的形态学操作,因此在地物混杂严重的情况下分类精度可能并不理想。AP是对物体间的属性差异进行度量,理论上更可靠,对于地物属性差异较大时能产生很好的效果,反之分类效果略低。DMP的精度稍逊色于EMP。riLBP对于地物内部纹理均匀的影像能够取得较好的分类精度,但计算效率较低。SLIC对于地

块形态相似时能产生良好的分割边界,但随着影像的增大,计算时间也显著增加。3D-Gabor仅能提取较粗的纹理特征,分类精度较低且计算时间最长,与光谱特征^[9]或LBP等细致的纹理特征结合^[34]能进一步提高分类效果。GF与JBF分类精度不理想但计算效率较高,在原始分类精度较高的情况下可以考虑结合二者进一步提高精度。

参考文献(References):

- [1] Tong Qingxi, Zhang Bing, Zhang Lifu. Current Progress of Hyperspectral Remote Sensing in China[J]. Journal of Remote Sensing, 2016, 20(5): 689-707. [童庆禧, 张兵, 张立福. 中国高光谱遥感的前沿进展[J]. 遥感学报, 2016, 20(5): 689-707.]
- [2] Chen Weimin, Zhang Ling, Song Dongmei, *et al.* Research on Hyperspectral Imagery Land Cover Classification Method based on AdaBoost Improved Random Forest [J]. Remote Sensing Technology and Application, 2018, 33(4): 612-620. [陈伟民, 张凌, 宋冬梅, 等. 基于AdaBoost改进随机森林的高光谱图像地物分类方法研究[J]. 遥感技术与应用, 2018, 33(4): 612-620.]
- [3] Sun W, Du Q. Hyperspectral Band Selection: A Review[J]. IEEE Geoscience and Remote Sensing Magazine, 2019, 7(2): 118-139. doi: 10.1109/MGRS.2019.2911100.
- [4] Sun W, Yang G, Peng J, *et al.* Hyperspectral Band Selection Using Weighted Kernel Regularization [J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2019, 12(9): 3665-3676. doi: 10.1109/JSTARS.2019.2922201.
- [5] Peng J, Sun W, Du Q. Self-paced Joint Sparse Representation for the Classification of Hyperspectral Images [J]. IEEE Transactions on Geoscience and Remote Sensing, 2018, 57(2): 1183-1194. doi: 10.1109/TGRS.2018.2865102.
- [6] Qian Jin, Luo Ding. Feature Extraction from Hyperspectral Remote Sensing Imagery based on Semisupervised Dimensionality Reduction with Pairwise Constraint [J]. Remote Sensing Technology and Application, 2016, 29(4): 681-688. [钱进, 罗鼎. 基于成对约束半监督降维的高光谱遥感影像特征提取[J]. 遥感技术与应用, 2016, 29(4): 681-688.]
- [7] Zhou Zhuang, Li Shengyang, Zhang Kang, *et al.* Crop Mapping Using Remotely Sensed Spectral and Context Features based on CNN [J]. Remote Sensing Technology and Application, 2019, 34(4): 694-703. [周壮, 李胜阳, 张康, 等. 基于CNN和农作物光谱纹理特征进行作物分布制图[J]. 遥感技术与应用, 2019, 34(4): 694-703.]
- [8] Su Hongjun. Spectral-Texture Feature Extraction and Classifier Ensemble for Hyperspectral Imagery [D]. Nanjing: Nanjing Normal University, 2011. [苏红军. 高光谱影像光谱-纹理特征提取与多分类器集成技术研究[D]. 南京: 南京师范大学, 2011.]
- [9] Bau T C, Sarkar S, Healey G. Using three-dimensional Spectral/spatial Gabor Filters for Hyperspectral Region Classification [C]// Algorithms and Technologies for Multispectral, Hyperspectral, and Ultraspectral Imagery XIV. International Society for Optics and Photonics, 2008, 6966: 69660E. doi: org/10.1117/12.777737.
- [10] Kang X, Li S, Benediktsson J A. Spectral-spatial Hyperspectral Image Classification with Edge-preserving Filtering [J]. IEEE Transactions on Geoscience and Remote Sensing, 2013, 52(5): 2666-2677. doi: 10.1109/TGRS.2013.2264508.
- [11] Li Z, Zhu Q, Wang Y, *et al.* Feature Extraction Method based on Spectral Dimensional Edge Preservation Filtering for Hyperspectral Image Classification [J]. International Journal of Remote Sensing, 2020, 41(1): 90-113. doi: org/10.1080/01431161.2019.1635723.
- [12] Solberg A H S, Taxt T, Jain A K. A Markov Random Field Model for Classification of Multisource Satellite Imagery [J]. IEEE Transactions on Geoscience and Remote Sensing, 1996, 34(1): 100-113. doi: 10.1109/36.481897.
- [13] Ghamisi P, Maggiori E, Li S, *et al.* New Frontiers in Spectral-spatial Hyperspectral Image Classification: The Latest Advances based on Mathematical Morphology, Markov Random Fields, Segmentation, Sparse Representation, and Deep Learning [J]. IEEE Geoscience and Remote Sensing Magazine, 2018, 6(3): 10-43. doi: 10.1109/MGRS.2018.2854840.
- [14] Gewali U B, Monteiro S T. A Tutorial on Modelling and Inference in Undirected Graphical Models for Hyperspectral Image Analysis [J]. International Journal of Remote Sensing, 2018, 39(20): 7104-7143. doi: org/10.1080/01431161.2018.1465614.
- [15] Zhong P, Wang R. Learning Conditional Random Fields for Classification of Hyperspectral Images [J]. IEEE Transactions on Image Processing, 2010, 19(7): 1890-1907. doi: 10.1109/TIP.2010.2045034.
- [16] Zhang X, Chew S E, Xu Z, *et al.* SLIC Superpixels for Efficient Graph-based Dimensionality Reduction of Hyperspectral Imagery [C]// Algorithms and Technologies for Multispectral, Hyperspectral, and Ultraspectral Imagery XXI. International Society for Optics and Photonics, 2015, 9472: 947209. doi: org/10.1117/12.2176911.
- [17] Benediktsson J A, Palmason J A, Sveinsson J R. Classification of Hyperspectral Data from Urban Areas based on Extended Morphological Profiles [J]. IEEE Transactions on Geoscience and Remote Sensing, 2005, 43(3): 480-491. doi: 10.1109/TGRS.2004.842478.
- [18] Dalla Mura M, Benediktsson J A, Waske B, *et al.* Morphological Attribute Profiles for the Analysis of Very High Resolution Images [J]. IEEE Transactions on Geoscience and Remote Sensing, 2010, 48(10): 3747-3762. doi: 10.1109/TGRS.2010.2048116]
- [19] Ghamisi P, Souza R, Benediktsson J A, *et al.* Extinction Profiles for the Classification of Remote Sensing Data [J]. IEEE Transactions on Geoscience and Remote Sensing, 2016, 54(10): 5631-5645. doi: 10.1109/TGRS.2016.2561842.
- [20] Hong D, Wu X, Ghamisi P, *et al.* Invariant Attribute Profiles: A Spatial-frequency Joint Feature Extractor for Hyperspectral Image Classification [J]. IEEE Transactions on Geoscience and Remote Sensing, 2020, 58(6): 3791-3808. doi: 10.1109/TGRS.2019.2957251.
- [21] Imani M, Ghassemian H. An Overview on Spectral and Spa-

- tial Information Fusion for Hyperspectral Image Classification: Current Trends and Challenges[J]. *Information Fusion*, 2020, 59: 59-83. doi:org/10.1016/j.inffus.2020.01.007.
- [22] Pan L, He C, Xiang Y, *et al.* Multiscale Adjacent Superpixel-Based Extended Multi-Attribute Profiles Embedded Multiple Kernel Learning Method for Hyperspectral Classification[J]. *Remote Sensing*, 2021, 13(1): 50. doi: org/10.3390/rs13010050]
- [23] Cao X, Yao J, Xu Z, *et al.* Hyperspectral Image Classification with Convolutional Neural Network and Active Learning[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2020, 58(7):4604-4616. doi: 10.1109/TGRS.2020.2964627.
- [24] Wang Fang, Yang Wunian, Wang Jian, *et al.*, Selection and Evaluation of the Optimal Scale in Multi-scale Segmentation of Remote Sensing Images[J]. *Remote Sensing Technology and application*, 2020, 35(3): 623-633.[王芳,杨武年,王建,等.遥感影像多尺度分割中最优尺度的选取及评价[J].遥感技术与应用,2020,35(3):623-633.]
- [25] Fauvel M, Tarabalka Y, Benediktsson J A, *et al.* Advances in Spectral-spatial Classification of Hyperspectral Images[J]. *Proceedings of the IEEE*,2012,101(3): 652-675. doi:10.1109/JPROC.2012.2197589.
- [26] Song C, Yang F, Li P. Rotation Invariant Texture Measured by Local Binary Pattern for Remote Sensing Image Classification[C]//2010 Second International Workshop on Education Technology and Computer Science. IEEE, 2010, 3: 3-6. doi: 10.1109/ETCS.2010.37.
- [27] Duan W, Li S, Fang L. Spectral-spatial Hyperspectral Image Classification Using Superpixel and Extreme Learning Machines [C] //Chinese Conference on Pattern Recognition. Springer, Berlin, Heidelberg, 2014: 159-167. doi: org/10.1007/978-3-662-45646-0_17.
- [28] Huang X, Zhang L. An SVM Ensemble Approach Combining Spectral, Structural, and Semantic Features for the Classification of High-resolution Remotely Sensed Imagery[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2012, 51(1):257-272.
- [29] Bao Rui, Xia Junshi, Xue Zhaohui, *et al.* Ensemble Classification for Hyperspectral Imagery based on Morphological Attribute Profiles[J]. *Remote Sensing Technology and Application*, 2016, 31(4):731-738.[鲍蕊,夏俊士,薛朝辉,等.基于形态学属性剖面的高光谱影像集成分类[J].遥感技术与应用,2016,31(4):731-730.]
- [30] Dalla Mura M, Atli Benediktsson J, Waske B, *et al.* Extended Profiles with Morphological Attribute Filters for the Analysis of Hyperspectral Data[J]. *International Journal of Remote Sensing*, 2010, 31(22): 5975-5991. doi: org/10.1080/01431161.2010.512425.
- [31] Bau T C, Sarkar S, Healey G. Hyperspectral Region Classification Using a Three-dimensional Gabor Filterbank[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2010, 48(9): 3457-3464. doi:10.1109/TGRS.2010.2046494.
- [32] Qiao T, Yang Z, Ren J, *et al.* Joint Bilateral Filtering and Spectral Similarity-based Sparse Representation: A Generic Framework for Effective Feature Extraction and Data Classification in Hyperspectral Imaging [J]. *Pattern Recognition*, 2018, 77: 316-328. doi: org/10.1016/j.patcog.2017.10.008.
- [33] He K, Sun J, Tang X. Guided Image Filtering[C]//European Conference on Computer Vision. Springer, Berlin, Heidelberg, 2010: 1-14. doi: org/10.1007/978-3-642-15549-9_1.
- [34] Li W, Chen C, Su H, *et al.* Local Binary Patterns and Extreme Learning Machine for Hyperspectral Imagery Classification [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2015, 53(7):3681-3693. doi:10.1109/TGRS.2014.2381602.

Comparison of Texture Feature Extraction Methods for Hyperspectral Imagery Classification

Shao Wenjing, Sun Weiwei, Yang Gang

(Department of Geography and Spatial Information Techniques, Ningbo University, Zhejiang 315211, China)

Abstract: The problem of “same object with different spectrum” and “different objects with same spectrum” makes that it difficult to obtain high classification accuracy for hyperspectral images using the single spectral information. Texture feature is the important structural information of spatial distribution of ground objects, which can compensate for the deficiency of spectral features in the classification to some extent. Many texture feature extraction methods have been developed in hyperspectral image classification, but they are lacking of a comprehensive comparative analysis. Therefore, this paper aim to explore the classification performance of different texture feature extraction methods. The 8 selected methods include rotational invariant local binary mode (riLBP), Simple Linear Iteration (SLIC), Extended Morphological Profile (EMP), Differential Morphological Profile (DMP), Attribute Profile (AP), 3D-Gabor, Joint Bilateral Filtering (JBF) and Guided Filtering (GF) design classification experiments. Experimental results on Indiana Pines, Pavia University and Xiong'an datasets show that EMP behaves better than other methods both in overall classification accuracy and computational speeds.

Key words: Hyperspectral remote sensing; Texture; Classification; Feature extraction