

基于多尺度特征提取的高光谱星载分类算法

袁帅, 孙亚男*, 何卫锋, 涂仕奎

上海交通大学电子信息与电气工程学院, 上海 200240

摘要 针对当前高光谱分类算法难以同时满足星载分类高精度、低能耗需求的问题,提出一种基于多尺度空间特征提取的高光谱星载分类算法,在保持较高分类精度的同时大幅度降低算法的计算开销。利用局部最大值滤波提取高光谱图像的纹理特征,将多尺度滤波结果根据遥感图像空间关联性进行组合得到局部-全局联合空间特征,融合空间特征和光谱特征后采用随机森林进行分类。该算法仅包含整数比较和加法运算,未采用高光谱主流分类算法中的乘法和求幂等高开销运算。在 Indian Pines、Pavia University 和 HyRANK 影像数据集上的实验结果表明,该算法与最高水平分类算法相比分类精度损失保持在 2.4% 以内,在跨场景分类中同样获得了较高的分类精度,与星载分类算法相比分类过程能耗降低到 1/10000 以下。该算法与现有算法相比更适用于星载分类任务,能够在保持较高分类精度的同时有效降低星载分类过程中的计算开销和能耗。

关键词 图像处理; 高光谱图像; 星载分类; 多尺度空间特征; 计算能耗优化

中图分类号 TP751

文献标志码 A

DOI: 10.3788/LOP213289

Hyperspectral On-Board Classification Algorithm Based on Multiscale Feature Extraction

Yuan Shuai, Sun Yanan*, He Weifeng, Tu Shikui

School of Electronic Information and Electrical Engineering, Shanghai Jiao Tong University, Shanghai 200240, China

Abstract Current hyperspectral classification algorithms cannot satisfy the requirements of high accuracy and low energy consumption of on-board classification simultaneously. A hyperspectral on-board classification algorithm based on multiscale spatial feature extraction is proposed to solve this problem. The proposed algorithm can significantly reduce the computational costs of the algorithm while maintaining high classification accuracy. Local maximum filtering is used to extract the texture features of hyperspectral images. The multiscale filtering results are combined with the spatial correlation of remote-sensing images to obtain joint local-global spatial features. After the spatial and spectral features are fused, the random forest is used for classification. The algorithm only includes integer comparison and addition operations and does not use high overhead operations, such as multiplication and exponentiation, in mainstream hyperspectral classification algorithms. Experimental results on Indian Pines, Pavia University, and HyRANK image datasets show that the algorithm's classification accuracy loss is within 2.4% compared with the highest-level classification algorithm. In addition, the proposed algorithm achieves high classification accuracy in cross-scene classification. The energy consumed in the classification process is reduced to less than 1/10000 compared with the on-board classification algorithm. Compared with existing algorithms, this algorithm is more suitable for on-board classification tasks and can effectively reduce the computational overhead and energy consumption during the on-board classification process while maintaining high classification accuracy.

Key words image processing; hyperspectral image; on-board classification; multiscale spatial feature; computational energy cost optimization

1 引言

高光谱成像因其信息量大而在不同领域有广泛的

应用,从高光谱图像中获得地物的精细光谱曲线可以用来准确区分不同地物。随着高光谱卫星传感器在光谱和空间分辨率上的提高,自然灾害分析和环境污染

收稿日期: 2021-12-20; 修回日期: 2022-01-26; 录用日期: 2022-02-08; 网络首发日期: 2022-02-18

基金项目: 国家自然科学基金(62174110)、上海市科学技术委员会项目(20501130400)

通信作者: *sunyanan@sjtu.edu.cn

监测等高光谱图像分类任务越来越受到关注。

传统的高光谱图像分类需要将卫星采集的海量原始数据传输到地面站进行解压、校正等预处理^[1],之后分发给各个实验室或用户进行分类和分析。整个流程在传输和预处理过程中消耗了大量的时间,使得遥感任务难以迅速完成。近些年提出的星载分类是一种有效的解决方法。通过在卫星上搭载嵌入式系统,使用训练后的算法模型对图像进行星载分类,能够消除大量数据传输和不必要的数据处理过程^[2],主要挑战在于如何高效实现星载分类以及如何对未知数据保持高分类精度。高光谱星载分类相关的研究工作通常使用嵌入式硬件架构进行算法验证,如现场可编程门阵列(FPGA)^[3-4]和高效图形处理器(GPU)^[5]。文献[3]和[4]分别使用极限学习机(ELM)和支持向量机(SVM)进行高光谱图像分类,而文献[5]使用卷积神经网络(CNN)。在文献[3]中,分别使用图像所有频段和图像的主成分作为ELM的输入来评估在FPGA和可编程化系统单芯片(PSoC)上的实现情况。文献[4]在FPGA上实现了SVM算法,并统计了执行算法的时间和所需的FPGA硬件资源。文献[5]在低功耗GPU上验证了CNN,并比较了使用低功耗GPU和高性能GPU执行算法时在运行时间和能耗上的差异。这些研究探索了实现高光谱星载分类系统的方法,但使用的算法仍然包含高计算开销的乘法和求幂运算。由于卫星能源有限,分类算法的计算开销直接影响到执行星载分类任务的次数,因此有必要对低计算开销优化方向进行研究。

现有高光谱图像分类算法可以根据学习特征的类型分为两类。第1类算法只使用每个像素的光谱特征进行分类,包括多项逻辑回归(MLR)、决策树(DT)、随机森林(RF)、ELM、SVM、多层感知器(MLP)和一维卷积神经网络(CNN1D)等。算法中运算的次数和类型(例如求幂、乘法、加法和比较)决定了执行的能耗。这些光谱特征分类算法(spectral algorithm)通常有着较少的运算次数,但由于缺少对空间特征的提取和学习,分类精度较低,不能为星载分类任务提供高质量的分类结果。第2类算法同时学习高光谱图像的光谱和空间特征,这类算法又可以根据结构特点分为两种,空谱一阶段分类算法(one-stage spatial-spectral algorithm)和空谱二阶段分类算法(two-stage spatial-spectral algorithm)。空谱一阶段分类算法会同时学习图像的空间和光谱特征并进行分类,通常具有很高的分类精度,如二维卷积神经网络(CNN2D)^[5-6]、三维卷积神经网络(CNN3D)^[7]、HybridSN^[8]和A²S²K-ResNet^[9]。然而这些算法都是由大量卷积层组成的复杂神经网络,由于计算过程包含乘法运算,每次卷积会消耗大量能量,它们得到的高分类精度是以高计算开销为代价的。空谱二阶段分类算法会在第1阶段进行特征提取和融合,使用的空间特征提取方法包括局部

二值模式(LBP)^[10]、扩展形态学剖面(EMP)^[11]或者深度神经网络的前几层(例如DeepLab^[12]和DCN^[13])等,然后在第2阶段使用SVM或RF等算法进行特征学习和分类。如果在第1阶段使用简单的特征提取方法,会使得分类精度远低于先进的一阶段算法,而使用较复杂的特征提取方法会导致较大的计算开销。尽管如此,二阶段分类算法提供了高度的灵活性,通过针对性设计空间特征提取方法和选择低计算复杂度的分类器,能够降低整体算法的计算开销同时保持高分类精度。因此,二阶段分类算法更适用于星载图像分类任务。

针对高光谱星载图像分类任务,本文根据高光谱图像特点和空间特征表示原理,提出一种基于多尺度局部最大值的空间特征提取方法与联合学习空谱特征的二阶段分类算法(MF-RF),该算法在得到接近当前最优算法的分类精度的同时保持了较高的跨场景分类精度。MF-RF算法消除了高计算开销的乘法和求幂运算并大幅度减少了算法中加法运算的次数,极大降低了算法星载执行的计算开销和相应能耗。假定MF-RF算法的训练过程于地面完成,以获取足够丰富的标记样本来提高算法的分类精度和泛化能力。针对高光谱星载分类任务,探索了同时满足高分类精度与低能耗的算法设计。

2 高光谱星载分类算法

2.1 高光谱星载分类算法整体结构

所提高光谱分类算法由第1阶段的基于多尺度局部最大值的空间特征提取方法和第2阶段的随机森林分类器组成。

最大值滤波是经典图像处理方法,通常被用于去除噪声、区域分离聚合、局部块或空洞检测等。本研究将最大值滤波应用于高光谱图像特征提取和分类领域,结合多尺度方法提取像素之间的空间相关性并增强分类器的输入特征。基于多尺度最大值滤波的空间特征提取方法如图1所示。首先计算高光谱图像在光谱维度上的平均值,获得光谱维均值图像来提取空间特征。在光谱维均值图像上进行多尺度局部最大值滤波,滤波窗口的半径逐渐增大,提取的多层空间特征依次堆叠得到每个像素的空间特征向量。在这个过程中可以通过调整最大半径的取值来得到最优分类结果。指定像素的空间特征向量值计算过程如下:

$$y(p, q, r) = \underset{p-r \leq i \leq p+r, q-r \leq j \leq q+r}{\text{Max}} \left[\frac{1}{N_{\text{bands}}} \sum_{k=1}^{N_{\text{bands}}} x(i, j, k) \right], r \in \left[1, \frac{s-1}{2} \right], \quad (1)$$

式中: $y(p, q, r)$ 为当前计算的 (p, q) 位置处空间特征向量的第 r 个值, r 为当前滤波器窗口半径; $x(i, j, k)$ 是位置 (i, j) 处的像素光谱向量的第 k 个值; N_{bands} 是光谱

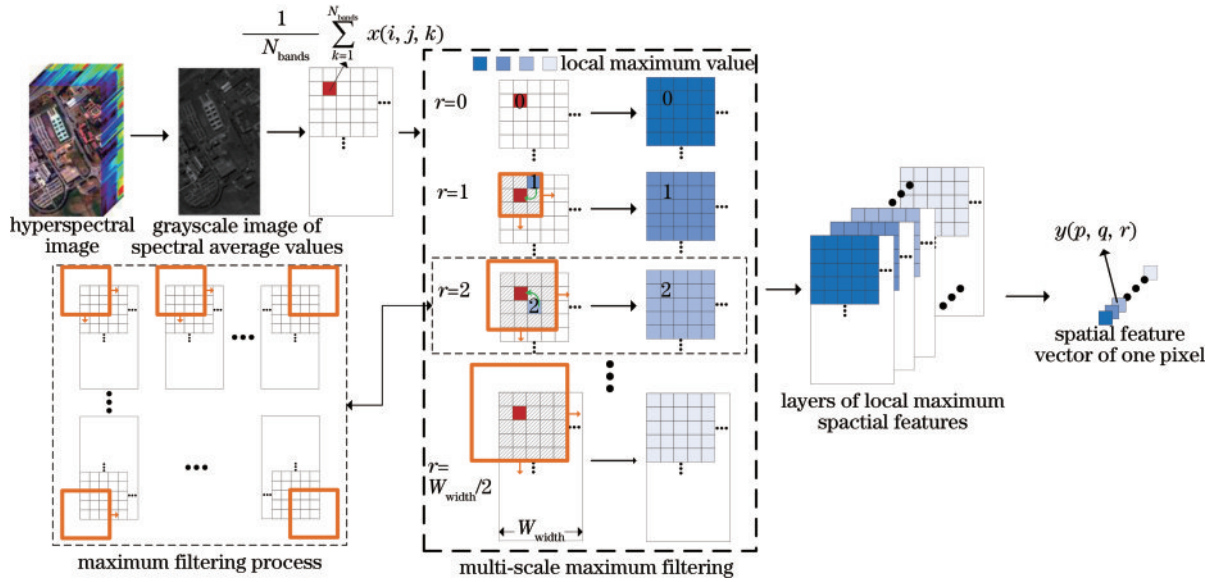


图 1 基于多尺度局部最大值的空间特征提取方法

Fig. 1 Spatial feature extraction method based on multiscale local maximum

波段的数量。完成滤波后,每个像素得到一个空间特征向量,包含该像素附近不同范围内的最大值。空间特征向量和原始光谱向量拼接形成的特征向量被传入算法第 2 阶段用于模型训练和图像分类。

在第 2 阶段,图像中选定样本的空间光谱联合特征向量被用来训练随机森林模型并对图像进行分类。随机森林算法是一种由多个决策树组成的集成学习方法,每个决策树都是一个弱分类器,用于对随机选择的特征进行分类。随机森林将所有树的结果进行整合,将次数最多的类别或平均计算的类别指定为最终输出。只有半数以上的决策树结果都出现错误时,随机森林才会得到错误的分类结果,其概率公式为

$$e_{\text{Random Forest}} = \sum_{i=N/2}^N C_N^i \varepsilon^i (1-\varepsilon)^{N-i}, \quad (2)$$

式中: N 是决策树数量; i 是判断错误的树的数量; $1-\varepsilon$ 是单棵决策树的分类精度; ε 是单棵决策树判断错误的概率。随机森林能够获得比决策树算法更高的分类精度,并有效提高了泛化能力。目前主流的分类算法都使用卷积神经网络,其分类器为最后的全连接层,其中,包含乘法、加法运算及由 Softmax 激活的求幂运算,有着较高的计算开销。随机森林的推理阶段主要由比较运算组成,运算量少,所以使用随机森林作为分类器时能耗更低。

所提星载高光谱分类算法中,空间特征提取方法和随机森林的主要运算类型都是整数比较,比乘法和求幂运算消耗更少的硬件资源和能量。此外,当算法部署在卫星上时,整数比较运算对宇宙射线引起的数据噪声或波动的容忍度超过深度神经网络中的乘法运算。

2.2 基于多尺度局部最大值的空间特征提取方法

所提特征提取方法 MF 使用最大值滤波来提取参

考像素不同范围内的空间锚点,这些锚点可以被视为图像纹理特征的主要组成部分。通过将不同尺度的特征值组合成空间特征向量,图像的局部和全局空间特征被有效地融合起来。该方法的计算过程仅由比较运算和极少量加法运算组成,与目前包含乘法运算的其他特征提取方法相比显著降低了能耗。

高光谱卫星以数百个连续且细分的光谱波段对目标区域同时成像,在空间特征提取之前首先要对高光谱图像进行降维。高光谱分类研究中的经常使用主成分分析(PCA)^[14]或线性判别分析(LDA)^[15]等方法。由于这些方法的计算过程中存在奇异值分解运算,迭代计算过程中会产生较大的计算开销,所以 MF 通过计算图像像素在光谱维度上的平均值来达到降维的目的,从而减小计算开销。

局部极值或“峰和谷”作为图像纹理可以用来表示图像的空间特征^[16],MF 特征提取方法选择使用最大值滤波作为基本运算单元。由于遥感图像的采集环境比自然照片更恶劣,图像的最小值特征容易被噪声污染。假设图像某局部区域的最大值为 a ,最小值为 b ,且 $a > b$,噪声值为 n ,则 $n/a < n/b$,所以使用最大值来表示纹理特征更不容易受到噪声的影响。在滤波过程中,每个滤波器中心像素值被窗口中的最大值代替。窗口随后分别向右和向下扫过整个图像,直到生成整个局部最大值特征层。当滤波器窗口超出图像边缘处时,仅计算滤波器窗口与图像的重叠部分。

为了增强特征提取能力,多尺度方法被用于 MF 的最大值滤波过程。在之前的研究中,LBP^[10]在 3×3 邻域中进行像素值比较,多尺度 CNN^[17]使用大小为 1×1 、 3×3 和 5×5 的卷积核,EMP^[11]通过有限次数的形态学开闭操作获得形态学特性,这些研究忽略了图像中有限区域之外的空间特征。受空间金字塔^[18]的启

发, MF 使用多尺度的最大值滤波器来生成相应的多层空间特征, 如图 1 所示。滤波器窗口尺寸逐渐增大, 空间特征层数随之增加, 产生的多尺度空间特征层数等于最大窗口半径值。最大滤波窗口的半径可以不断增加, 直至图像长宽较小值的一半, 此时滤波器窗口近似覆盖整个图像, 生成的局部空间特征已可被视为全局特征。MF 特征提取方法在由局部到全局的过程中较完备地提取了主要空间特征, 一定程度上弥补了使用均值计算作为降维方法造成的特征损失。

由于遥感图像的像素具有空间相关性, 相邻像素更有可能属于同一类别, 因此不同范围内的最大值能够用来建立中心像素的空间特征向量。建立过程基于图像上下文分类原理, 即每个像素的空间特征可以由指定邻域中像素值组成的向量表示。传统的上下文分类使用四连通或八连通的 3×3 邻域, 而 MF 空间特征提取方法使用多尺度方法, 能够获得更完备的空间特征。多个最大值滤波器得到的局部极值组合在一起以构成局部-全局联合空间特征向量。该过程可以被认为是以多个局部到全局范围内的最大值为锚点在空间中定位当前像素。

在所提分类算法的第 1 阶段中, 基于多尺度局部最大值的空间特征提取方法能够以低计算复杂度提取图像的主要空间特征, 提高整体算法的分类精度。

2.3 算法分类过程的计算复杂度对比分析

为了比较分析不同类别高光谱分类算法的计算复杂度, 在表 1 中分别列出了部分代表性算法在分类过程中平均每个像素的运算次数统计公式。第 1 类算法为只使用光谱特征的分类算法 SVM、RF 和 CNN1D;

第 2 类为联合使用空谱特征的一阶段分类算法 CNN2D^[5]、HybridSN^[8]和 A²S²K-ResNet^[9]; 第 3 类为使用 LBP、EMP 与随机森林组成的空谱特征二阶段分类算法。其中, HybridSN^[8]和 A²S²K-ResNet^[9]是目前分类精度最高的算法, SVM 和 CNN2D 作为星载分类算法分别用于文献[3]和文献[5]。由于空谱特征一阶段分类算法主要由卷积层组成, 所以表 1 中统一给出了每个像素经过单个卷积层的运算次数, 各空谱特征一阶段分类算法的运算次数根据实际的网络结构对多个卷积层的运算次数进行累加来获得。表 1 中的求幂(Exp)、乘法(Mul)和加法(Add)运算为浮点数运算, 而比较(Cmp)运算为整数运算。EMP-RF 算法需要先对光谱数据进行降维, 运算操作次数大多被 PCA 降维方法占用, 而 PCA 降维的运算次数取决于软件实现方法和计算迭代次数, 所以在表 1 中以 Mul(PCA)和 Add(PCA)表示。

在表 1 的所有算法中, RF、LBP-RF 和所提 MF-RF 算法仅包含比较和加法运算, 在计算复杂度上显著低于包含求幂运算和乘法运算的其他算法。由于随机森林的每棵树会从所有特征中随机选取部分特征, 这些算法中 RF 的平均数深度 D 通常小于输入特征数量, 这使得 RF、LBP-RF 和 MF-RF 在运算次数上也低于其他算法。所提 MF-RF 算法由 MF 空间特征提取方法和 RF 分类器组成。目前高光谱分类算法通常使用神经网络的卷积层来进行空间特征提取。在传统空间特征提取方法中, LBP 算法和形态学特征提取方法(包括 MF 使用的最大值滤波和 EMP 形态学滤波)仅使用比较运算, 在计算开销上比卷积层更低。现有的高光谱分类算法通常使用 RF、SVM 和 CNN 中最后一

表 1 不同算法的运算类型与次数统计

Table 1 Statistics of operation type and number of operations of different algorithms

Algorithm	Number of operations			
	Exp	Mul	Add	Cmp
SVM	M	$kM + 2M$	$kM + l$	
		M : number of support vectors		
Spectral algorithm(k : number of features, l : number of classes)	RF		N	DN
	CNN1D		$(k - q + 1)ql$	$(k - q + 1)ql$
		q : number of values in each filter		
One-stage spatial-spectral algorithm(K : kernel size, C_{in} : number of input channels, C_{out} : number of output channels)	Each convolution layer		$K^2 \times C_{in} \times C_{out}$	$K^2 \times C_{in} \times C_{out}$
	LBP-RF		N	$k'p + DN$
		p : number of points in LBP, D/N : same as RF		
Two-stage spatial-spectral algorithm(k' : number of features)	EMP-RF	Mul(PCA)	Add(PCA) + N	$\sum_1^m S_i^2 + DN$
	MF-RF	Mul(PCA)、Add(PCA): number of Mul/Add in PCA, S_i : size of each structuring element, m : number of structuring elements, D/N : same as RF	N	$(2r_{max} + 1)^2 + DN$
		r_{max} : radius of the largest filter, D/N : same as RF		

层全连接层作为分类器,其中,RF分类器在分类过程中有着最低的计算开销。所以相比于其他算法,MF-RF在低计算复杂度方面有着较大优势。

3 实验结果与分析

3.1 实验数据集

实验使用 Indian Pines 和 Pavia University 数据集测试和比较不同算法的分类精度,使用 HyRANK 数据集测试所提算法的跨场景分类性能。

Indian Pines 数据集由 AVIRIS 传感器在印第安纳州西北部采集,包括 224 个光谱波段,大小为 145×145 。去除受水汽影响较大的波段后的数据集包含 200 个波段,10249 个像素被标记,包含 16 个地物类别。

Pavia University 数据集由 ROSIS 传感器在意大利北部帕维亚采集,包括 103 个光谱波段,大小为 610×340 ,几何分辨率为 1.3 m。42776 个像素被标记,包含 9 个地物类别。

HyRANK 数据集由 EO-1 卫星采集,包含 176 个光谱波段和 14 个地物类别。HyRANK 数据集包含 Dioni 和 Loukia 两个场景。Dioni 场景大小为 250×1376 ,20024 个像素被标记。Loukia 场景大小为 245×945 ,13503 个像素被标记。测试算法时从两个场景中选择 12 个相同的类别。

3.2 实验设计与参数设置

为了验证算法的分类性能,将 MF-RF 算法与 3 类代表性算法在 Indian Pines 和 Pavia University 数据集

上的分类结果进行对比。RF 和其他算法中的 RF 分类器都由 100 棵树组成。SVM 和 CNN2D 的参数与文献[4]和[5]相同。CNN1D 使用 20 个尺寸为 24 的卷积核。CNN1D 和 CNN2D 都使用 Softmax 激活函数。HybridSN 和 A²S²K-ResNet 的结构也与文献[8]和文献[9]相同。LBP-RF 算法与 MF-RF 使用相同的降维方法,并在光谱维均值的结果上应用多尺度的 LBP 算子。EMP-RF 算法与文献[11]相同。数据集中的数据首先被缩小到 8 位整型(0~255)以模拟在卫星上进行特征提取和图像分类的过程。在数据集中随机选取 10% 的像素作为训练样本,每个类别训练样本的比例相同,其余数据作为测试集。

为了验证 MF-RF 算法的跨场景分类情况,分别使用 RF 算法和 MF-RF 算法在 HyRANK 数据集上对不同场景进行分类。在 HyRANK 数据集中,设置 Dioni 场景为源场景,Loukia 场景为目标场景。在实验中使用 L1 归一化和标准化来消除不同场景间的光谱差异,并测试使用 CORAL 迁移学习方法后的分类结果。在 Dioni 源场景中随机选取 10% 的像素作为训练样本,每个类别训练样本的比例相同,Loukia 目标场景的所有数据作为测试集。

3.3 分类精度结果与分析

各算法在 Indian Pines 和 Pavia University 数据集上的各类别精度、总分类精度(OA)、平均分类精度(AA)和 Kappa 系数分别如表 2 和表 3 所示,分类效果如图 2 和图 3 所示。在 Indian Pines 数据集上,RF 分

表 2 Indian Pines 数据集分类结果

Table 2 Classification results on Indian Pines dataset

unit: %

Class	Spectral algorithm			One-stage spatial-spectral algorithm			Two-stage spatial-spectral algorithm		
	SVM	RF	CNN1D	CNN2D	HybridSN	A ² S ² K-ResNet	LBP-RF	EMP-RF	MF-RF
Alfalfa	81.82	100.00	87.50	100.00	80.49	100.00	95.24	97.83	91.84
Corn-notill	78.91	73.58	73.38	90.24	95.10	97.78	82.34	94.76	95.49
Corn-mintill	80.69	75.93	75.30	90.85	99.46	98.69	88.00	95.17	94.72
Corn	63.14	59.60	79.31	87.98	93.90	96.27	74.05	83.87	93.81
Grass-pasture	92.83	88.70	91.39	93.95	98.16	99.31	97.17	94.00	96.21
Grass-trees	85.24	82.98	94.59	93.98	99.24	99.44	88.18	97.90	95.45
Grass-pasture-mowed	83.87	100.00	95.00	100.00	100.00	92.22	90.00	100.00	89.66
Hay-windrowed	92.59	86.34	93.25	98.73	99.53	99.32	94.43	100.00	97.95
Oats	100.00	100.00	100.00	90.91	61.11	84.65	100.00	100.00	100.00
Soybean-notill	80.05	72.25	82.65	91.12	98.17	97.56	92.16	92.94	95.96
Soybean-mintill	77.97	73.37	69.97	94.80	99.05	99.13	86.45	94.68	96.16
Soybean-clean	77.26	66.60	85.78	92.58	90.26	98.10	87.74	89.64	92.95
Wheat	90.13	90.91	94.34	95.71	95.14	99.20	100.00	100.00	98.51
Woods	93.25	93.06	93.31	96.48	99.47	99.29	99.37	99.21	99.61
Buildings-Grass-Trees-Drives	73.82	58.43	71.70	96.21	95.97	98.00	97.49	94.33	98.21
Stone-Steel-Towers	98.77	98.75	100.00	78.38	90.48	96.30	92.86	97.89	98.78
OA	82.34	77.62	80.11	93.43	97.44	98.57	89.66	95.15	96.26
AA	84.39	82.53	86.72	93.24	93.47	97.20	91.59	95.76	95.96
Kappa	79.75	74.26	77.01	92.50	97.08	98.37	88.14	94.46	95.73

表 3 Pavia University 数据集分类结果

Table 3 Classification results on Pavia University dataset

unit: %

Class	Spectral algorithm			One-stage spatial-spectral algorithm			Two-stage spatial-spectral algorithm		
	SVM	RF	CNN1D	CNN2D	HybridSN	A ² S ² K-ResNet	LBP-RF	EMP-RF	MF-RF
Asphalt	93.60	92.03	95.15	98.75	100.00	99.76	97.12	99.40	98.68
Meadows	96.17	90.22	98.17	99.33	100.00	99.95	98.65	99.82	99.30
Gravel	88.38	86.50	89.82	97.90	98.68	99.42	96.69	99.86	98.76
Trees	96.25	96.21	95.10	96.19	99.45	99.88	97.10	99.90	99.14
Painted metal sheets	99.04	98.23	99.63	99.56	100.00	99.97	99.48	100.00	99.85
Bare Soil	94.65	92.93	91.94	99.26	100.00	99.96	98.26	99.94	99.80
Bitumen	92.73	86.11	92.05	92.81	100.00	100.00	99.13	99.70	99.62
Self-Blocking Bricks	86.00	82.08	85.33	97.48	99.70	99.00	93.86	99.08	99.17
Shadows	100.00	100.00	99.37	99.55	94.60	100.00	99.79	99.68	99.79
OA	94.41	90.56	95.07	98.58	99.72	99.81	97.81	99.71	99.25
AA	94.09	91.59	94.06	97.87	99.11	99.77	97.79	99.71	99.35
Kappa	92.56	87.26	93.48	98.12	99.63	99.75	97.10	99.62	99.01




图 2 各算法在 Indian Pines 数据集上的分类效果图。(a) 真值图; (b) SVM; (c) RF; (d) CNN1D; (e) CNN2D; (f) HybridSN; (g) A²S²K-ResNet; (h) LBP-RF; (i) EMP-RF; (j) MF-RF

Fig. 2 Classification maps of each algorithm on Indian Pines dataset. (a) Ground truth; (b) SVM; (c) RF; (d) CNN1D; (e) CNN2D; (f) HybridSN; (g) A²S²K-ResNet; (h) LBP-RF; (i) EMP-RF; (j) MF-RF

类器中树的数量设置为 100 左右时分类精度最高。在 Pavia University 数据集上, RF 分类器中有着 120 棵左右的树时可得到最高的分类精度。为了在统一标准下对比各算法,在本次实验中将 RF 分类器中树的数量参数设置为 100。另外在 MF-RF 第 1 阶段的空间特征提取方法中,最大的滤波器半径是每个数据集的宽度和高度较小值的一半时(即两个数据集对应的 r_{\max} 分别为 72 和 169), MF-RF 取得最高的分类精度。

从表 2 和表 3 可以看出,只使用图像光谱特征算法(SVM、RF 和 CNN1D)的分类精度明显低于其他使用空谱特征的算法。因此,综合学习高光谱图像的空间和光谱特征有利于提高算法的总体分类精度。MF-RF 在两个数据集上的分类精度分别为 96.26% 和 99.25%, 远高于仅使用光谱特征算法的分类精度。

与使用空谱特征的一阶段算法相比, MF-RF 在两个数据集上与最优分类精度的差值分别为 2.31 个

百分点和 0.56 个百分点, MF-RF 的分类精度与当前最先进高光谱分类算法的精度非常接近。与结构相似并同样使用 RF 作为分类器的 LBP-RF 相比, MF-RF 在两个数据集上的平均分类精度分别提高了 6.6 个百分点和 1.44 个百分点。在空间特征提取阶段, MF 通过使用像素值本身而不是 LBP 中像素的大小关系提取了更多的空间特征。与使用 PCA 降维的 EMP 相比, MF 中的多尺度方法填补了使用均值计算作为降维方法造成的精度损失, 并由于最大值滤波选择图像的主要空间特征使得平均分类精度略有提升。

星载分类是为了满足突发自然灾害、环境事故等紧急情况下的快速响应需求而提出的。在星载分类消除了传统遥感任务过程中的大量数据传输时间后, 算法分类过程占用的时间成为影响任务响应速度的主要因素。各分类算法的分类过程时间统计如表 4 所示。HybridSN 和 A²S²K-ResNet 算法使用 Nvidia Tesla




图3 各算法在Pavia University数据集上的分类效果图。(a) 真值图; (b) SVM; (c) RF; (d) CNN1D; (e) CNN2D; (f) HybridSN; (g) A²S²K-ResNet; (h) LBP-RF; (i) EMP-RF; (j) MF-RF

Fig. 3 Classification maps of each algorithm on Pavia University dataset. (a) Ground truth; (b) SVM; (c) RF; (d) CNN1D; (e) CNN2D; (f) HybridSN; (g) A²S²K-ResNet; (h) LBP-RF; (i) EMP-RF; (j) MF-RF

表4 不同算法在两个数据集上的分类时间

Table 4 Classification times of different algorithms on two datasets

unit: s

Dataset	Spectral algorithm			One-stage spatial-spectral algorithm			Two-stage spatial-spectral algorithm		
	SVM	RF	CNN1D	CNN2D	HybridSN	A ² S ² K-ResNet	LBP-RF	EMP-RF	MF-RF
Indian Pines	3.41	0.54	1.20	6.11	72.30	45.68	4.38	1.48	1.07
Pavia University	39.23	4.15	7.43	59.56	277.31	117.42	79.70	12.69	16.69

V100 显卡进行训练和分类,其他算法使用了 Intel i3-4160 处理器。CNN2D 和 EMP-RF 算法调用库对 PCA 降维过程进行了优化,减少了计算时间。

从表 4 可以看出,光谱特征分类算法中 RF 和 CNN1D 算法的分类所需时间较少。空谱特征一阶段分类算法中,HybridSN 和 A²S²K-ResNet 算法对运行环境的性能有更高要求,同时需要较多的时间才能完成分类。空谱二阶段分类算法 LBP-RF 和 EMP-RF 的分类时间仍高于 MF-RF 算法。文献[4]和文献[5]中使用的星载分类算法 SVM 和 CNN2D 的分类时间是 MF-RF 算法的 2~6 倍。与其他分类算法相比,MF-RF 算法的分类过程仅需要较少的计算时间,适用于高光谱星载分类任务。

3.4 跨场景分类验证

实际的高光谱星载分类任务中需要完成对高光谱图像的跨场景分类,即在地面使用具有类别标记的高

光谱数据作为源场景训练算法模型,随后在星上使用模型对新拍摄的目标场景进行分类。由于大气和光照条件、传感器的非线性特性、同一地物类别的不同物质成分等因素的影响,源场景和目标场景之间会出现光谱漂移和失真,所以目前跨场景分类仍然是高光谱图像分类的主要挑战之一。

为了验证 MF-RF 算法的跨场景分类效果,使用了 HyRANK 高光谱数据集,数据集中的 Dioni 和 Loukia 场景拍摄于不同的时间和地点。在模型训练和分类之前可以对高光谱数据进行处理来减少不同场景之间的光谱差异,以此获得更好的分类结果。归一化(normalization)和标准化(standardization)都是图像分类中常用的数据处理方法。当用于高光谱图像时,L1 归一化方法可以减轻不同场景之间光照和大气条件等导致的光谱幅度偏移。标准化方法同样可以减少光谱幅度差异,并能够降低不同场景下光谱向量方差对算

法训练的影响。L1 归一化和标准化方法计算复杂度较低,不会对星载分类增加过多的能耗。另外,高光谱跨场景分类属于迁移学习中的域自适应领域,在实验中使用 CORAL 域自适应方法^[19]以进一步提高跨场景分类精度。CORAL 方法通过对齐源域和目标域数据分布的协方差来减少域之间的分布偏移。相对于其他传统域自适应方法,CORAL 方法有着更低的计算复杂度,并且由于该方法中没有需要调整的超参数,分类

结果更加稳定。由表 1 算法分类过程的计算复杂度分析可知,RF 算法和 MF-RF 算法更适合用于星载分类任务,所以选择了这两种算法作为分类算法。不同的数据处理方法和分类算法组合在 HyRANK 数据集上的分类结果如表 5 所示,L1 表示 L1 归一化方法,ST 表示标准化方法。表 5 中 MF-RF 算法后括号里的数字代表算法取得最佳分类结果时的空间特征层数。

表 5 HyRANK 数据集的分类结果
Table 5 Classification results on HyRANK dataset

unit: %

Class	RF	L1+RF	ST+RF	ST+CORAL+RF	MF-RF(17)	ST+CORAL+MF-RF(52)
Dense Urban Fabric	5.78	29.17	4.39	3.70	8.21	15.49
Mineral Extraction Sites	0.00	17.07	16.24	34.09	2.50	33.33
Non-Irrigated Arable Land	25.00	83.14	45.71	92.18	66.67	76.61
Fruit Trees	0.00	0.00	1.52	3.05	0.00	1.96
Olive Groves	2.22	44.44	0.00	81.40	0.00	62.63
Coniferous Forest	100.00	87.50	64.60	39.49	85.71	28.15
Dense Sclerophyllous Vegetation	67.54	67.88	68.45	71.68	66.59	69.38
Sparce Sclerophyllous Vegetation	44.33	37.46	51.43	49.70	45.65	51.60
Sparcely Vegetated Areas	9.38	11.66	4.99	17.28	9.29	17.92
Rocks and Sand	9.45	28.00	56.91	57.32	8.93	58.40
Water	62.28	95.15	100.00	100.00	67.64	100.00
Coastal Water	3.01	100.00	100.00	99.34	2.15	96.16
OA	46.66	51.99	55.45	58.59	48.57	60.03
AA	27.42	50.12	42.85	54.10	30.28	50.97
Kappa	33.13	41.27	45.95	49.92	35.52	50.67

从表 5 可以看出,数据预处理方法能够提高 RF 算法 5.33 个百分点以上的分类精度,标准化方法比 L1 归一化提高了 3.46 个百分点的分类精度,更适合用于消除 HyRANK 数据集中不同场景间的光谱偏差。CORAL 方法配合标准化方法将 RF 的分类精度提高了 11.93 个百分点。单独使用 MF-RF 算法对 HyRANK 数据集进行分类的结果比单独使用 RF 算法高 1.91 个百分点。在使用了标准化方法和 CORAL 方法后,MF-RF 算法取得了 60.03% 的分类精度。从以上实验结果来看,所提 MF-RF 算法在跨场景分类中同样能够获得较高的分类精度。

最后,实际星载分类任务的情况与以上实验不完全相同。在实验中,数据集中样本标记区域大小等因素会影响到 MF-RF 算法空间特征层数的最佳取值,训练样本也仅限于单个场景中的像素数据和类别。在实际的星载分类任务中可以标记出更丰富的训练样本数据,而且能够使用远多于单个场景的样本数据来训练分类算法,所以分类结果会优于以上实验的结果。

3.5 分类算法有效性验证

所提算法主要包含比较运算,为了验证星载环境下算法中的比较运算对噪声的容忍度超过乘法和加法运算,在高光谱数据集上人为添加高斯噪声^[20],并对 RF 算法和 CNN1D 算法的分类结果进行对比。另外,所提空

间特征提取方法使用最大值滤波来获取纹理特征的主要部分,遥感图像的最小值更容易被噪声污染。为了验证使用最大值滤波作为空间特征提取基本运算单元的抗噪声能力,在空间特征提取方法中分别使用最大值和最小值作为特征值进行对比。不同噪声峰值信噪比 (PSNR) 情况下各算法的分类 OA 数据如表 6 所示。

从表 6 可以看出,尽管所有情况下 RF 算法的分类精度都比 CNN1D 算法低,但 CNN1D 的分类精度随着噪声增加而下降的速度比 RF 更快,比较运算比乘法和加法运算对噪声容忍度更高。所提使用最大值滤波的 MF-RF 算法对噪声的容忍程度高于 RF 算法。当图像无噪声时,使用最大值的 MF-RF 算法得到了比使用最小值更高的分类精度。随着噪声增强,使用最大值作为特征值得到的分类精度仍显著高于使用最小值作为特征值的精度。在图像质量较好的 Pavia University 数据集中,少量噪声不影响 MF-RF 的分类效果。根据分类结果可以得出,对于高光谱遥感图像,使用最大值来表示纹理特征更不容易受到噪声的影响。

为了进一步衡量所提空间特征提取方法有效性,对不同的特征提取方法和分类器组合设计两次对比实验。首先,表 2 和表 3 中各算法使用的分类器为 SVM、RF 和 CNN 的最后一个全连接层,分别将 SVM 和全连接层作为分类器替换 MF-RF 算法中的 RF 并组合为

表 6 噪声情况下 RF、CNN1D 和基于不同特征值的 MF-RF 分类结果对比

Table 6 Classification results of RF, CNN1D, and MF-RFs based on different feature values

unit: %

Dataset	PSNR /dB	RF	CNN1D	MF-RF (minimum)	MF-RF (maximum)
Indian Pines		77.62	80.11	93.76	96.26
	36.38	77.10	80.07	93.27	95.07
	26.38	74.14	76.19	93.04	94.67
Pavia University		90.56	95.07	99.06	99.25
	35.07	89.94	93.61	98.80	99.28
	25.07	85.79	87.77	97.94	99.31

新的算法(MF-SVM、MF-FC),分类结果如表 7 所示。其中,全连接层使用 Softmax 激活函数,且结构与其他 CNN 算法中一致。从表 7 可以看出,使用全连接层分类器的 MF-FC 的分类精度低于使用 SVM 和 RF 作为分类器的分类精度。当使用 SVM 作为分类器时,所提特征提取方法仍然能够有效提取空间特征,并得到了近似于 MF-RF 的分类精度,远高于表 2 和表 3 中仅使用 SVM 进行分类的精度。

表 7 MF 与不同分类器组合对比

Table 7 Comparison of MF and different classifiers combinations

unit: %

Dataset		MF-SVM	MF-FC	MF-RF
Indian Pines	OA	94.89	79.61	96.26
	AA	95.60	76.72	95.96
	Kappa	94.17	76.62	95.73
Pavia University	OA	99.47	90.46	99.25
	AA	99.49	89.13	99.35
	Kappa	99.29	87.33	99.01

随后测试不同的 CNN 特征提取部分与 RF 组合算法的分类精度。分别从光谱特征分类算法和空谱特征一阶段分类算法中选择 CNN1D 和 CNN2D 两种算法,将最后一层全连接层替换为 RF 分类器,分类结果如表 8 所示。当使用相同的 RF 分类器时,所提空间特征提取方法的性能优于 CNN1D 和 CNN2D 中的卷积层。综合比较表 2、表 3 和表 8 中空谱特征二阶段算法的分类结果可知,所提空间特征提取方法的性能优于特征提取算子 LBP 和简单结构的 CNN 卷积层,接近

表 8 不同 CNN 特征提取方法与 RF 组合对比

Table 8 Comparison of different CNN feature extraction

methods and RF combinations unit: %

Dataset		CNN1D- RF	CNN2D- RF	MF-RF
Indian Pines	OA	80.88	92.53	96.26
	AA	87.78	93.65	95.96
	Kappa	77.93	91.44	95.73
Pavia University	OA	95.37	97.93	99.25
	AA	95.19	97.79	99.35
	Kappa	93.83	97.25	99.01

形态学滤波 EMP 和复杂的 CNN 卷积结构。以上对比结果证明了所提空间特征方法的有效性。

3.6 各类运算次数统计与分析

为了分析算法的计算复杂度,一种广泛采用的度量方式是统计模型分类过程中整数和浮点运算的次数,即模型理论计算量。算法计算过程中的运算类型和数量直接决定了在星载分类过程中的计算开销和能耗。MF-RF 算法与其他算法的运算操作类型和操作次数比较结果如图 4 所示,运算类型包括整数比较(integer comparison)、浮点加法(floating-point addition)、浮点乘法(floating-point multiplication)和浮点求幂(floating-point exponentiation)。运算次数来自于表 1 中的公式并基于对不同算法分类过程的评估。图 4 中展示的是各算法运算操作次数平均到每个像素的值,在统计过程中不考虑算法的软件优化手段。图 4(a)~(c)中 MF-RF 统计结果为相同数值。

从图 4(a)可以看出,SVM 在分类时产生了远超过同类算法的运算次数,并且其中还包含幂运算。RF 在分类过程中只需要很少的运算。另外由于运算类型的不同,RF 中的比较运算在硬件上的开销也比其他算法更低,所以使用 RF 作为分类器的算法比其他算法更适合用于星载分类。CNN1D 算法的运算操作数量高于 RF 和所提 MF-RF,同时 CNN1D 中包含的乘法和加法运算也需要更多的计算开销。

从图 4(b)可以看出,MF-RF 算法的运算次数比 HybridSN 和 A²S²K-ResNet 的运算次数分别减少到约 1/10⁴和 1/10⁶,而在分类精度上最多降低了 2.5 个百分点。与星载分类算法 CNN2D 相比,MF-RF 的运算次数降低到约 1/10³而分类精度略有提升。考虑到 CNN2D、HybridSN 和 A²S²K-ResNet 由乘法和加法运算组成,MF-RF 的实际计算开销会更低。

在综合学习空谱特征的二阶段算法中,LBP-RF 在每个 LBP 尺度下仅使用了固定个数的像素与中心像素进行比较,运算次数低于 MF-RF,但 LBP-RF 在 Indian Pines 数据集上的分类精度比 MF-RF 降低了 6.6 个百分点。EMP-RF 的运算操作次数大多被 PCA 降维方法占用,使得 EMP-RF 在两个数据集上的运算次数分别为 MF-RF 的 10³倍和 6 倍。造成这个差异的原因是 Indian Pines 的光谱谱段数接近 Pavia

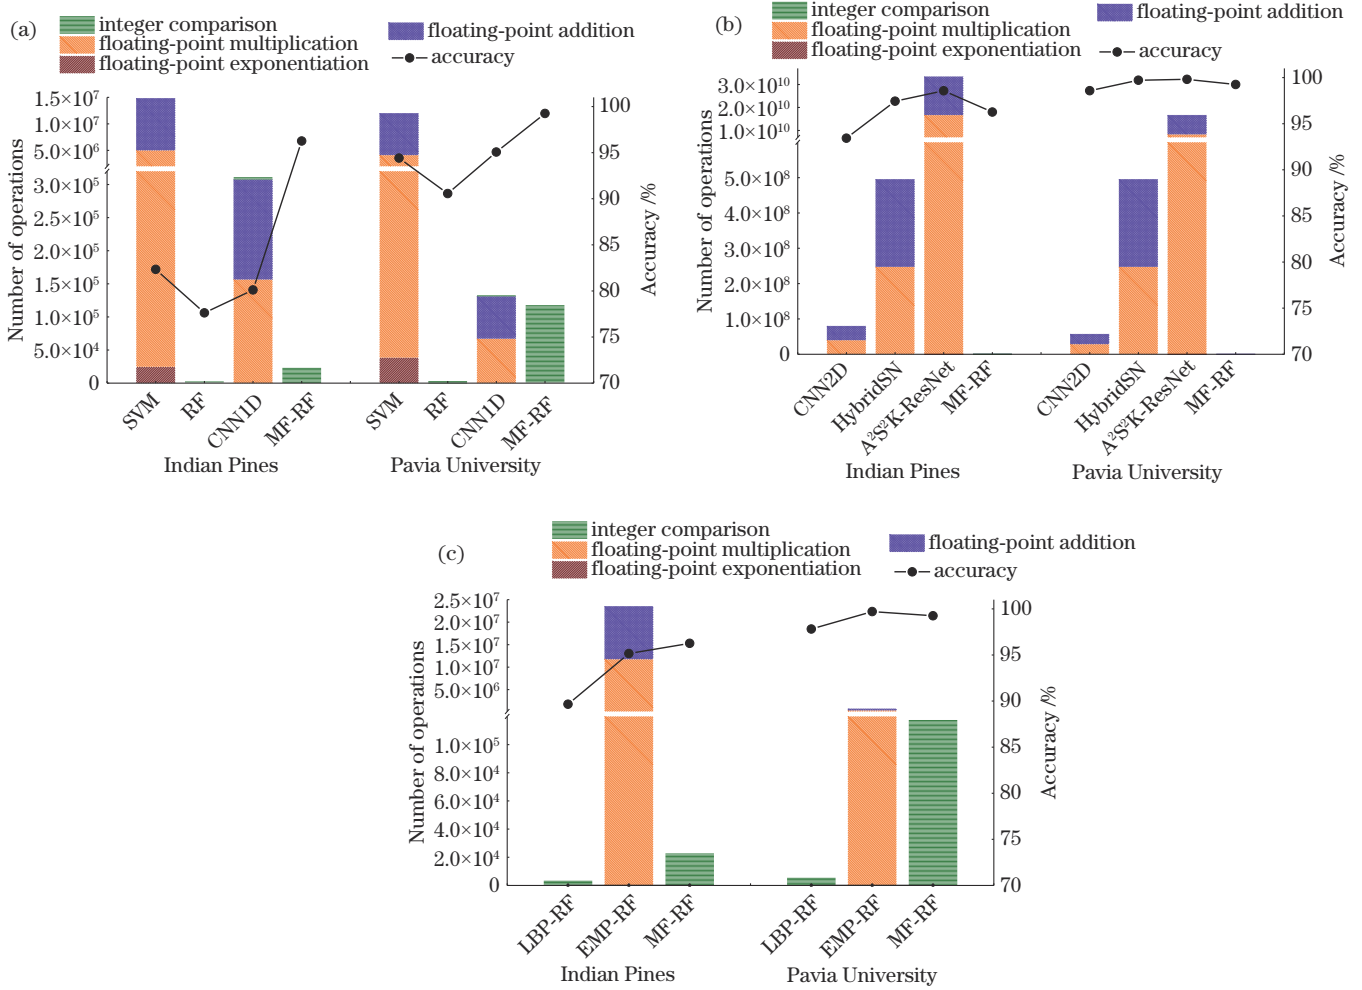


图 4 各算法分类过程的运算操作次数。(a)光谱分类算法;(b)空谱一阶段分类算法;(c)空谱二阶段分类算法

Fig. 4 Number of operations in the classification process of each algorithm. (a) Spectral algorithms; (b) one-stage spatial-spectral algorithms; (c) two-stage spatial-spectral algorithms

University 的两倍,这使得 EMP-RF 中 PCA 的计算量呈指数级增长。

MF-RF 算法的空间特征提取方法基于多尺度最大值滤波,仅由整数比较运算和少量加法运算组成。考虑到不同的运算类型和 8 位整型数据精度, MF-RF 的计算开销优势更为明显。MF-RF 算法只需比较最大尺度滤波窗口中的所有值即可获得当前像素的空间特征向量,算法的计算复杂度主要由最大滤波器尺寸决定且呈平方关系。如果对计算过程进行优化,使得每个滤波窗口的比较运算次数进一步减少,统计的运算数量将远小于图 4 中的结果。另外,调整 RF 分类器中树的数量后, MF-RF 算法的运算次数和相应能耗的数量级保持不变。

3.7 能耗统计与分析

在各算法的实际分类过程中,浮点乘法和加法的数据精度都是 32 位。SVM 中浮点求幂的精度也是 32 位,运算的基数是定值 e。整数比较运算主要被用于 RF 以及使用 RF 作为分类器的算法(包括 MF-RF),数据精度为 8 位。文献[21]中提供了硬件电路每次执行浮点

加法和乘法的运算能耗,如表 9 所示。整数比较和浮点求幂的运算能耗是通过在相似硬件环境(40 nm 芯片工艺, 0.9 V 工作电压)下进行电路仿真得到的。在使用 40 nm 工艺的 FPGA 或低功耗 GPU 执行算法时,表 9 中的数据可以作为实际运算电路能耗数据直接使用。最后,每种算法执行分类过程的总能耗值如表 10 所示,在图 5 中展示了不同算法在能耗数量级上的差异。

表 9 不同运算操作类型的能耗

Table 9 Energy consumption of different operation types

Operation type	Data precision /bit	Energy cost /pJ
Integer comparison	8	0.008
Floating-point addition	32	0.9
Floating-point multiplication	32	3.7
Floating-point exponentiation	32	38.975

表 10 的数据表明, MF-RF 的能耗与各个类别的不同算法相比都处于较低的水平。从图 5 可以看出,只有 RF 和 LBP-RF 的能耗比 MF-RF 更低,约为 MF-RF 的 0.1,但是这两种算法在分类精度上远低于 MF-

表 10 各算法在分类过程中的能耗
Table 10 Energy consumption of each algorithm in classification process unit: pJ

Classification algorithm	Indian Pines	Pavia University
SVM	2.8×10^7	2.4×10^7
RF	1.0×10^2	1.1×10^2
CNN1D	7.2×10^5	3.1×10^5
CNN2D	1.8×10^8	1.3×10^8
HybridSN	1.1×10^9	1.1×10^9
A ² S ² K-ResNet	7.7×10^{10}	3.8×10^{10}
LBP-RF	1.1×10^2	1.3×10^2
EMP-RF	5.4×10^7	1.8×10^6
MF-RF	2.7×10^2	1.0×10^3

RF。空谱特征一阶段分类算法的能耗非常高,为 MF-

RF 的 10^5 倍以上,不适合星载分类。空谱特征二阶段分类算法中不同的算法能耗差异明显,这验证了二阶段算法在分类精度和能耗之间进行权衡的灵活性。最后,目前星载分类研究[3-5]中使用的算法(SVM 和 CNN2D)的能耗分别高于所提 MF-RF 约 10^4 和 10^5 倍。文献[3-5]中使用的 FPGA 和 GPU 硬件环境也同样适用于运行所提星载分类算法 MF-RF,并且图像分类过程中的能耗会大幅度降低。

以上对分类精度、不同运算操作数量统计和能耗的综合分析结果充分验证了所提算法的优越性,该算法能够以较低的计算开销完成预定的星载分类任务。长期使用 MF-RF 算法进行高光谱星载分类能够有效降低所需的能量,并缓解高光谱卫星的数据传输带宽和存储容量紧张的问题。

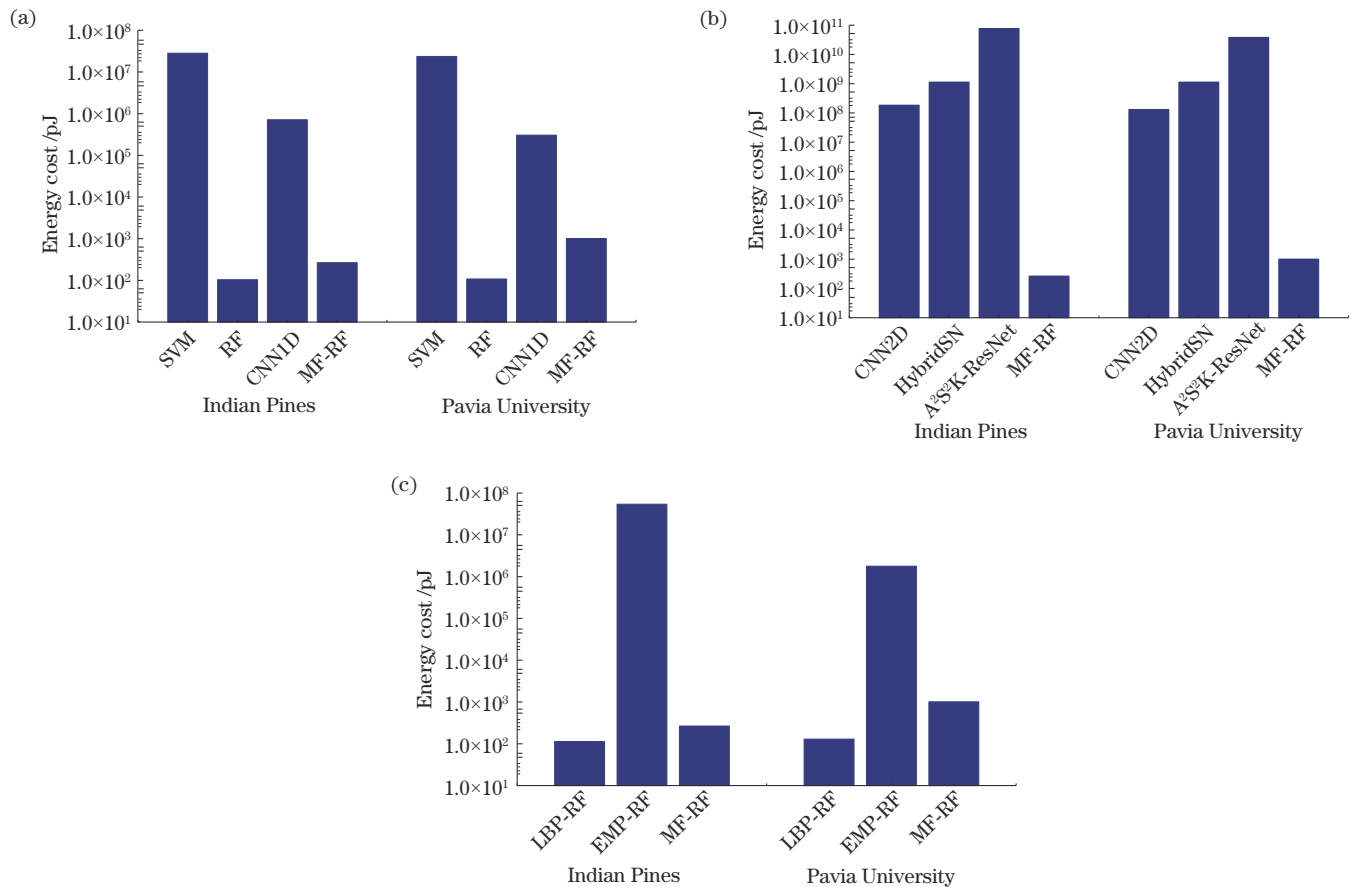


图 5 各算法分类过程中的能耗。(a)光谱分类算法;(b)空谱一阶段分类算法;(c)空谱二阶段分类算法

Fig.5 Energy consumption of each algorithm in the classification process. (a) Spectral algorithms; (b) one-stage spatial-spectral algorithms; (c) two-stage spatial-spectral algorithms

4 结 论

针对星载分类任务提出一种新的高光谱图像分类算法 MF-RF,由基于多尺度局部最大值的空间特征提取方法和用于分类的随机森林组成。该算法主要针对硬件进行优化,分类过程中仅使用了 8 位整数比较和极少量的加法运算。使用 Indian Pines、Pavia University 和 HyRANK 数据集进行实验, MF-RF 取得了与目前

最高水平高光谱分类算法接近的分类精度和较高的跨场景分类性能,并大幅度降低了分类过程的计算复杂度和能耗。与高光谱星载分类算法相比, MF-RF 同时获得了更高的分类精度和更低的能耗。实验结果表明,该算法与现有算法相比更适用于星载分类任务,能够在保持较高分类精度的同时有效降低星载分类过程中的计算开销和能耗。后续将继续优化算法以进一步提高分类精度并降低分类过程的计算开销。

参 考 文 献

- [1] Ma Y, Wu H P, Wang L Z, et al. Remote sensing big data computing: challenges and opportunities[J]. *Future Generation Computer Systems*, 2015, 51: 47-60.
- [2] Alcolea A, Paoletti M E, Haut J M, et al. Inference in supervised spectral classifiers for on-board hyperspectral imaging: an overview[J]. *Remote Sensing*, 2020, 12(3): 534-562.
- [3] Basterretxea K, Martinez-Corral U, Finker R, et al. ELM-based hyperspectral imagery processor for onboard real-time classification[C]//2016 Conference on Design and Architectures for Signal and Image Processing (DASIP), October 12-14, 2016, Rennes, France. New York: IEEE Press, 2016: 43-50.
- [4] Martins L A, Sborz G A M, Viel F, et al. An SVM-based hardware accelerator for onboard classification of hyperspectral images[C]//SBCCI '19: Proceedings of the 32nd Symposium on Integrated Circuits and Systems Design, August 26-30, 2019, São Paulo, Brazil. New York: ACM Press, 2019.
- [5] Haut J M, Bernabé S, Paoletti M E, et al. Low-high-power consumption architectures for deep-learning models applied to hyperspectral image classification[J]. *IEEE Geoscience and Remote Sensing Letters*, 2019, 16(5): 776-780.
- [6] Makantasis K, Karantzas K, Doulamis A, et al. Deep supervised learning for hyperspectral data classification through convolutional neural networks[C]//2015 IEEE International Geoscience and Remote Sensing Symposium, July 26-31, 2015, Milan, Italy. New York: IEEE Press, 2015: 4959-4962.
- [7] 国强, 彭龙. 基于三维卷积神经网络与超像素分割的高光谱分类[J]. *光学学报*, 2021, 41(22): 2210001.
Guo Q, Peng L. Hyperspectral classification based on 3D convolutional neural network and super pixel segmentation[J]. *Acta Optica Sinica*, 2021, 41(22): 2210001.
- [8] Roy S K, Krishna G, Dubey S R, et al. HybridSN: exploring 3-D-2-D CNN feature hierarchy for hyperspectral image classification[J]. *IEEE Geoscience and Remote Sensing Letters*, 2020, 17(2): 277-281.
- [9] Roy S K, Manna S, Song T C, et al. Attention-based adaptive spectral-spatial kernel ResNet for hyperspectral image classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2021, 59(9): 7831-7843.
- [10] 职露, 余旭初, 付琼莹. 联合局部二值模式的高光谱影像空-谱分类方法[J]. *测绘科学技术学报*, 2018, 35(1): 65-69, 76.
Zhi L, Yu X C, Fu Q Y. Hyperspectral imagery spatial-spectral classification combining local binary patterns[J]. *Journal of Geomatics Science and Technology*, 2018, 35(1): 65-69, 76.
- [11] 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.
- [12] Niu Z J, Liu W, Zhao J Y, et al. DeepLab-based spatial feature extraction for hyperspectral image classification [J]. *IEEE Geoscience and Remote Sensing Letters*, 2019, 16(2): 251-255.
- [13] Li T, Leng J B, Kong L Y, et al. DCNR: deep cube CNN with random forest for hyperspectral image classification[J]. *Multimedia Tools and Applications*, 2019, 78(3): 3411-3433.
- [14] 叶珍, 白璘. 基于主成分分析与局部二值模式的高光谱图像分类[J]. *激光与光电子学进展*, 2017, 54(11): 111006.
Ye Z, Bai L. Hyperspectral image classification based on principal component analysis and local binary patterns[J]. *Laser & Optoelectronics Progress*, 2017, 54(11): 111006.
- [15] Bandos T V, Bruzzone L, Camps-Valls G. Classification of hyperspectral images with regularized linear discriminant analysis[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2009, 47(3): 862-873.
- [16] Mitchell, Myers, Boyne. A max-min measure for image texture analysis[J]. *IEEE Transactions on Computers*, 1977, C-26(4): 408-414.
- [17] 张祥东, 王腾军, 杨耘. 基于多尺度残差网络的小样本高光谱图像分类[J]. *激光与光电子学进展*, 2020, 57(16): 162801.
Zhang X D, Wang T J, Yang Y. Classification of small-sized sample hyperspectral images based on multi-scale residual network[J]. *Laser & Optoelectronics Progress*, 2020, 57(16): 162801.
- [18] Lazebnik S, Schmid C, Ponce J. Beyond bags of features: spatial pyramid matching for recognizing natural scene categories[C]//2006 IEEE Computer Society Conference on Computer Vision and Pattern Recognition, June 17-22, 2006, New York, NY, USA. New York: IEEE Press, 2006: 2169-2178.
- [19] Sun B C, Feng J S, Saenko K. Return of frustratingly easy domain adaptation[C]//AAAI'16: Proceedings of the Thirtieth AAAI Conference on Artificial Intelligence, February 12-17, 2016, Phoenix, Arizona, USA. New York: ACM Press, 2016: 2058-2065.
- [20] Pu H Y, Chen Z, Wang B, et al. A novel spatial-spectral similarity measure for dimensionality reduction and classification of hyperspectral imagery[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2014, 52(11): 7008-7022.
- [21] Horowitz M. 1.1 Computing's energy problem (and what we can do about it)[C]//2014 IEEE International Solid-State Circuits Conference Digest of Technical Papers, February 9-13, 2014, San Francisco, CA, USA. New York: IEEE Press, 2014: 10-14.