

DOI: 10.19650/j.cnki.cjsi.J2615087

基于光谱-改进纹理特征树状分析的云图 分类方法及 FPGA 计算加速^{*}

于希明, 彭 宇, 刘连胜

(哈尔滨工业大学电子与信息工程学院 哈尔滨 150001)

摘 要:云图分类方法旨在判断遥感图像中是否包含云,对于在轨云检测任务具有重要的价值。当前云图分类方法主要包括基于阈值、机器学习和深度学习的方法。尽管基于深度学习的云图分类方法可以为复杂场景下云的准确检测提供更好的性能,但其处理耗时长,占用星载资源多。因此,研究者通常选择基于阈值的方法结合多种纹理特征为基础的机器学习的方法实现在轨高效云判。然而,为了应对如冰雪等高亮地表的干扰,当前云图分类方法在构建复杂纹理特征时存在计算复杂以及中间结果数据量大等问题,严重影响其处理效率。因此,提出了一种基于光谱-改进纹理特征树状分析的云图分类方法,并通过现场可编程门阵列(FPGA)对其进行计算加速。该方法通过两级自适应阈值设置树状分支,快速检出图像中的暗地表,以简化算法计算过程。同时,设计一种新颖的灰度共生矩阵(GLCM)对角线特征,在保持对云和高亮地表区分能力的同时降低计算复杂性。此外,利用FPGA对耗时较长的像素值统计过程进行加速计算。实验结果表明,与分类精度较高的MobileNetV3方法相比,所提方法在达到相近的云误检率的同时操作数减少99%以上,中间结果数据量减少95%以上。此外,所提算法的计算结构可以在1.20 s内实现对一幅7 300×6 908 pixels的遥感图像的处理,极大提升了处理效率。

关键词:云图分类;自适应阈值;改进纹理特征;FPGA加速;在轨云检测

中图分类号: TP751.1 TH701 **文献标识码:** A **国家标准学科分类代码:** 510.40

Cloud image classification method based on tree analysis process using spectral-improved texture features and FPGA computing acceleration

Yu Ximing, Peng Yu, Liu Liansheng

(School of Electronics and Information Engineering, Harbin Institute of Technology, Harbin 150001, China)

Abstract: Cloud image classification aims to judge whether there is cloud in remote sensing images, which plays an important role in onboard cloud detection tasks. Cloud image classification methods mainly include threshold-based, machine learning-based, and deep learning-based approaches. While deep learning-based cloud image classification methods can provide better performance for accurate cloud detection under complex scenarios, they suffer from long processing time and high onboard resource consumption. Therefore, scholars usually select threshold-based methods combined with machine learning methods based on multiple texture features to realize high-efficiency on-orbit cloud discrimination. However, in order to deal with the interference of high-brightness ground objects such as ice and snow, there are problems such as complex calculation and large amount of intermediate result data when constructing features in cloud image classification method. These problems seriously affect processing efficiency. Therefore, a cloud image classification method based on tree analysis process using spectral-improved texture features is proposed in this article, and it is accelerated by field-programmable gate array (FPGA). The proposed method quickly detects the dark ground in the image through tree branch setting constructed by two levels of adaptive threshold, which simplifies the method calculation. Furthermore, a novel diagonal feature of gray level co-occurrence matrix (GLCM) is designed to reduce the calculation complexity while maintaining the ability to distinguish between cloud and high-brightness ground. In addition, the time-consuming pixel statistics process is accelerated by FPGA. Experimental results demonstrate that the proposed method has a reduction of more than 99% in the number of operations and more than 95% in the volume of

收稿日期:2026-03-30 Received Date: 2026-03-30

^{*} 基金项目:黑龙江省重点研发计划(2023ZX01A13)项目资助

intermediate data than MobileNetV3 with high classification accuracy, while achieving a similar cloud false alarm rate. In addition, the acceleration architecture of the proposed method can achieve processing for an image with a resolution of 7 300×6 908 pixels in 1.20 s, which greatly improves the efficiency.

Keywords: cloud image classification; adaptive threshold; improved texture feature; FPGA acceleration; onboard cloud detection

0 引 言

云是一种常见的自然现象,地球表面 66% 以上都被云层所覆盖^[1]。由于可见光难以穿透云层,因此有云覆盖的遥感图像将被改变甚至丢失原本的辐射信息,形成白色高亮的干扰区域。在遥感图像进行高层次解译前需要对云进行检出,减少冗余数据。随着遥感图像处理效率的需求日益提升,当前研究者不仅关注如何提升云检测算法精度,还重点针对高性能处理器平台部署下云检测算法高效运行方法开展研究^[2-4]。与传统在地面服务器中部署云检测算法不同,云检测算法在轨运行通常需要借助数字信号处理器(digital signal processor, DSP)、现场可编程门阵列(field programmable gate array, FPGA)与嵌入式图形处理器(graphics processing unit, GPU)等嵌入式高性能处理器的帮助^[5]。此类处理器在计算和存储资源方面限制较大,因此在轨云检测算法更加关注算法精度与所付出的处理耗时、存储占用等代价的平衡。

按照分类粒度的不同,现有云检测算法可分为云图分类方法与像素级分类方法。其中,云图分类方法是对图像整体是否包含云进行判断,而像素级分类方法需要对图像中每个像素的类别进行独立判断。相较而言,云图分类方法无法对云所在位置和在图像中的占比进行准确的描述,但是其处理过程相对简单,处理效率更高,因此在以高效处理为目标的在轨云检测应用中仍具有重要的作用^[6-9]。通过云图分类方法,可以快速对含云量较大的遥感图像进行排除,减少无效数据对有限星载资源的占用。此外,云图分类方法还可以作为像素级分类云检测算法的预处理过程,在保持高精度检测能力的同时有效提升整体处理效率^[10]。开发计算简单、存储需求小的云图分类方法具有重要价值。

特征构建是影响云图分类方法计算复杂度以及存储占用的关键因素。当前,云检测算法主要包括基于光谱特性的阈值法、多种人工特征组合为特征向量判据的机器学习方法,以及基于卷积网络自动提取特征的深度学习^[11-22]。相较而言,基于光谱阈值的云图分类方法虽然不如基于深度学习的方法可以面向复杂场景提供精确的云判,但其计算过程简单,所产生的中间结果数据量较少,更容易应用于在轨环境中。然而,由于遥感图像中云和地表类型复杂,极难获取能够准确区分云和地表的阈值。相关研究利用能够描述像素空间分布特性的纹理

特征与 K 近邻、聚类或支持向量机(support vector machine, SVM)等机器学习分类器相结合,进而对阈值法进行补充。但是在构建复杂纹理特征时产生的计算量与数据量剧增,成为其在轨应用的阻碍。因此,在考虑对云和地表有效区分的基础上,构建更简单的纹理特征并简化算法流程,并利用高性能处理器进行加速计算,是实现在轨云图分类的关键。

基于以上问题,本文提出一种基于光谱-改进纹理特征树状分析的云图分类方法,并通过在 FPGA 上设计并行计算结构对其进行计算加速。该方法通过大津法获得自适应阈值设置选择分支,对云和与其在光谱特性上具有较大差异的暗地表进行快速的区分,使得计算较复杂的纹理特征仅在云和高亮地表的区分上使用,减少算法整体计算复杂度,并减少不同类型地表之间的干扰。同时,对现有纹理特征进行改进,在保持对云和地表区分能力的同时降低计算二次统计特征时产生的操作数和中间结果数据量,提高其在有限资源高性能处理器中应用的能力。此外,对像素统计过程基于 FPGA 设计并行加速结构,有效提高算法处理效率。

本文的主要贡献为:

1) 设计了一种基于树状分析的云图分类流程,利用两级全局自适应阈值将暗通道值较低的非云地表图像进行快速的检出,有效减少算法整体计算复杂度;

2) 提出了一种新颖的灰度共生矩阵(gray level co-occurrence matrix, GLCM) 对角线特征,在保留对云和地表纹理分析能力的同时将二维 GLCM 统计过程化简为一维直方图统计,有效降低了复杂纹理特征求解的计算难度以及占用的存储资源,更有利于在星载有限存储资源条件下的在轨处理;

3) 构建了一种基于 FPGA 的像素值统计并行加速结构,有效提升了包含大量像素的宽幅遥感图像直方图统计过程的处理效率。

1 光谱-改进纹理特征树状分析的云图分类

1.1 云图分类方法总体流程

现有可见光遥感图像包含海量像素,依次遍历所有位置以判断云是否存在需要耗费大量的星载资源,且时间成本巨大。考虑到遥感图像中通常包含不同类型的场景,其中常见的水体、土壤和植被等场景与云在光谱特性上差异较大,通过简单的光谱阈值即可实现有效的区分。

而复杂的纹理或几何特征可以集中应用于更难检的高亮地表。这意味着通过对不同场景图像进行区分化的处

理,可以有效减少算法整体复杂度。基于以上分析,本文提出一种树状分析流程,如图 1 所示。




图 1 云图分类方法总体流程

Fig. 1 The overall framework of cloud image classification

根据方法流程可以看到,本文所提方法主要通过两级全局自适应阈值 th_1 和 th_2 对不同场景构建不同的处理分支,其主要处理流程可以分成 3 个阶段:

1) 图像暗通道变换及像素值缩放。本文所提方法输

入为一幅尺寸为 $H \times W$, 具有红、绿和蓝 3 种光谱通道的完整宽幅遥感图像,目标为对其切割出的所有子图进行分类。为了完成这一目标,在算法之初需要对宽幅遥感图像进行暗通道变换。暗通道先验理论是 He 等^[23] 于

2010 年所提去雾算法中应用的一种先验理论。其主要思想是采用一个像素中值最小的光谱通道来代表整个像素,称为暗通道。由于云在红、绿和蓝三通道上普遍都具有较大的值,而大部分地表在某一光谱通道上值较低,因此采用暗通道变换可以更好的突出图像中的云。在获得暗通道图之后,需要进一步对所有像素暗通道的灰度级范围进行缩小。该操作可以提高后续直方图统计与 GLCM 纹理特征提取处理速度。灰度级缩放的数学表达如式(1)所示。

$$I_{x,y}^{\text{scale}} = (I_{x,y} - I_{\min}) \times \frac{I_{\max}^{\text{scale}} - I_{\min}^{\text{scale}}}{I_{\max} - I_{\min}} + I_{\min}^{\text{scale}} \quad (1)$$

式中: $I_{x,y}$ 为原始图像中坐标位置在 (x,y) 的像素暗通道值; $I_{x,y}^{\text{scale}}$ 为对应位置像素在缩放后的暗通道值; $I_{\min}$ 为原始图像中像素暗通道最小值; $I_{\max}$ 为原始图像中像素暗通道最大值; $I_{\min}^{\text{scale}}$ 为缩放后图像像素暗通道最小值; $I_{\max}^{\text{scale}}$ 为缩放后图像像素暗通道最大值。

2) 基于两级全局自适应阈值的分支处理。通过对遥感图像的统计分析可以发现,图像中存在大量暗通道值较小的暗地表,且这些暗地表内部暗通道值较一致,因此易在直方图上聚集在暗通道值较小的区域形成“尖峰”;相对的,云与高亮地表则易聚集在暗通道值较大的区域形成“尖峰”。两者在暗通道上的差距使得利用图像全局阈值对其类别进行判定成为可能。根据以上分析,通过在完整宽幅遥感图像上获取全局阈值 th_1 ,实现对不同类型子图的分支处理。假设一张宽幅遥感图像可切割为 $S_1 \times S_2$ 张尺寸为 $H_1 \times W_1$ 的子图,则 $S_1 = \text{ceil}(H/H_1)$, $S_2 = \text{ceil}(W/W_1)$, $\text{ceil}(\cdot)$ 为向上取整。利用阈值 th_1 与每一张子图中像素暗通道最大值与最小值进行比较,当子图中像素暗通道最小值大于 th_1 时,表明该子图有较大概率含有云;而当子图中像素暗通道最大值小于 th_1 时,表明该子图中不含云。这两种处理分支中直接输出子图类型。其他子图为疑似有云子图,这些子图中可能同时存在暗地表、云和高亮地表,需要采用第二级阈值 th_2 进一步处理。

在第二级阈值判断过程中,需要将疑似有云子图切割成若干图像块进行处理。假设一张子图可分割为 $S_3 \times S_4$ 张尺寸为 $H_2 \times W_2$ 的图像块,则 $S_3 = \text{ceil}(H_1/H_2)$, $S_4 = \text{ceil}(W_1/W_2)$ 。这些图像块通过阈值 th_2 进入两个分支进行处理,分别为暗通道均值大于 th_2 的高亮图像块处理分支和其他图像块处理分支。其中,高亮图像块可能包含云图像块和高亮地表图像块。由于两者具有相似的光谱特性,因此仅通过光谱阈值难以有效区分,需要利用纹理特征对图像块像素空间分布特性进行表征。本文基于云检测领域常用的 GLCM 特征描述图像块的纹理,并且从减少其计算产生操作数和中间结果数据量的角度对其进行改进,设计了一种新颖的 GLCM 对角线特征,并以

此为基础构建特征向量,作为 K-means 聚类算法的输入,对高亮图像块所属类别进行判定。对于其他图像块,可能包含纯地表或地表与云混存的碎云,由于碎云与地表在均值和标准差等局部特征上的差异,设计阈值对其进行进一步的区分,以提升对云的检测能力。通过以上过程,可以获得疑似有云子图中所有图像块的类别判定结果。

3) 子图类别判定。本文设计方法中,通过子图中所有图像块的类别决定子图类别。在得到所有图像块类别后,计算其中类别为非云地表的图像块的数量,当数量大于预设阈值 th_{land} 时,则认为该子图为非云子图,否则为含云子图。

通过以上流程,充分的利用了不同类型地表与云在光谱或纹理特征上的差异,同时极大的减少了纹理特征处理次数,提升了算法整体计算效率。对于算法整体而言,两级自适应阈值设置与 GLCM 对角线特征的设计是影响算法计算复杂度的最大因素,因此后续主要对这两方面内容进行具体的阐述。

1.2 两级全局自适应阈值

通过总体流程分析可知,本文所提出的方法需要在阈值的控制下完成不同类型子图的划分,从而实现分支处理。由于不同遥感图像的暗通道分布具有一定差异,采用固定阈值易导致图像类型划分错误,因此本文采用大津法针对不同图像计算自适应阈值。

大津法(也称为最大类间方差法)是一种广泛应用的阈值自适应提取方法^[24]。由于其计算简单,该方法在提出后在不同领域都得到了广泛应用。给定一张 $M \times N$ 大小,像素值范围为 $[L_{\min}, L_{\max}]$ 的图像, $L_{\min}$ 与 $L_{\max}$ 分别为图像中像素最小值与最大值,则像素值为 l 的像素在图像中出现概率如式(2)所示。

$$p_l = \frac{\text{Num}(l)}{M \times N} \quad (2)$$

式中: $\text{Num}(l)$ 为像素值为 l 的像素在图像中的数量。

假设图像中包含两类像素,其中一类像素构成集合 A ,其像素值范围为 $[L_{\min}, L_T - 1]$;另一类构成集合 B ,其像素值范围为 $[L_T, L_{\max}]$ 。依照大津法,利用像素出现概率可以计算得到集合 A 的概率 P_A 与均值 μ_A ,集合 B 的概率 P_B 和均值 μ_B ,以及图像整体平均值 μ 。利用以上参量可得到集合 A 与 B 的类间方差如式(3)所示。

$$\sigma^2 = P_A \cdot (\mu_A - \mu)^2 + P_B \cdot (\mu_B - \mu)^2 \quad (3)$$

一般情况下,需要将 L_T 在 $[L_{\min}, L_{\max}]$ 上进行遍历,当取得 σ^2 最大时,对应的 L_T 为图像最佳分割阈值。

由于大津法在类间方差计算过程中产生的操作数与中间结果数据量较小,因此其在计算和存储资源严格受限的在轨处理器平台应用时具有良好的适应能力。为了

使大津法在遥感图像上对云和地表获得较好的分割阈值, L_T 遍历范围的选择是关键。

对于第一级全局自适应阈值而言,其主要目的是对宽幅遥感图像中无云覆盖的地表子图和云与地表共存的疑似有云子图加以区分,因此 L_T 应在最大可能代表地表的暗通道值与代表云的暗通道值之间进行遍历。通过对遥感图像的统计分析可以发现,除了一些特殊的高亮地表外,大部分地表暗通道值较低,且地表内部暗通道值比较一致,这使得这些暗地表在直方图上通常位于值较低的区域,且易形成像素数量较多、分布较紧凑的“尖峰”形状。然而,由于现有宽幅遥感图像覆盖地面范围较广,单个像素位宽较大,使得其对于场景的区分更加细致,导致直方图中代表暗地表的“尖峰”可能不止有一个。为了使大部分暗地表能够通过第一级自适应阈值进行检出,有效减少后续纹理分支所需处理的数据量,减少算法整体流程的复杂度, L_T 应选择具有最大暗通道值的“尖峰”开始遍历。在本文中,判断 L_T 遍历的起始点 L_{start} 如式(4)和(5)所示。

$$\text{peak}(l) = \begin{cases} 1, & p_l > p_{l-1}, p_l > p_{l+1} \\ \text{Num}(l) \geq th_{\text{num}}, \sigma_{\Omega}(l) \leq th_{\sigma} & (4) \\ 0, & \text{其他} \end{cases}$$

$$L_{\text{start}} = \max_{L_{\min} \leq l \leq L_{\text{ave}}} (l \cdot \text{peak}(l)) \quad (5)$$

式中: $\max(\cdot)$ 代表集合内的最大值; L_{ave} 是整幅遥感图像的暗通道均值; $\sigma_{\Omega}(l)$ 代表直方图上以暗通道值 l 为中心的窗口 Ω 内暗通道标准差; th_{num} 和 th_{σ} 分别代表暗通道数量和标准差阈值,在本文中通过统计取值分别为 1 000 000 和 3。

通过上述公式可以发现,为了得到第一级全局自适应阈值的遍历起始点 L_{start} ,首先需要通过式(4)计算暗通道值 l 对应的“尖峰”判定函数 $\text{peak}(l)$ 。暗通道值 l 在直方图上被判定为“尖峰”的条件是值为 l 的像素出现频次高于值为 $l-1$ 和 $l+1$ 的像素,且值为 l 的像素数量大于预设阈值 th_{num} ,在窗口 Ω 内的标准差小于预设阈值 th_{σ} 。在该函数判定下,可以排除数量较少或分布分散的“尖峰”的干扰。之后,寻找具有最大暗通道值的“尖峰”。考虑到暗地表通常暗通道值较小,因此以整幅图像均值 L_{ave} 为边界进行最大值的选择。最后,以此最大暗通道值作为遍历起始点 L_{start} ,根据大津法可以计算得到第一级全局自适应阈值 th_1 。

对于第二级全局自适应阈值而言,其主要目标是对疑似有云子图内含云和高亮地表图像块进行筛选,从而利用纹理特征进一步增强云和地表的区分能力。疑似有云子图中还包含一些暗地表图像块,这些图像块暗通道均值一般较小,而含云和高亮地表图像块暗通道均值较大。然而,由于每张子图只反映宽幅遥感图像的局部场

景,不同子图在光谱分布特性上可能具有较大差异,因此若采用固定阈值对所有子图进行处理易导致分类错误,因此本文利用第一级自适应阈值 th_1 作为第二级阈值的遍历起始点,对不同子图自动寻找适合的阈值 th_2 进行图像块分类。

1.3 GLCM 对角线特征

1) 原始 GLCM 特征及问题

利用 1.2 节设计的全局自适应阈值,可以将暗通道值较小的暗地表进行快速的分类,但对于光谱特性相似,均具有较高暗通道值的云和高亮地表则难以区分。为此,本文采用在云检测领域常用的 GLCM 特征来表征云和高亮地表在空间分布纹理特征上的差异,以增强算法对云和地表的分类能力。假设存在一幅尺寸为 $M \times N$ 像素的遥感图像,像素的灰度级为 L_g , $0 \leq i, j \leq L_g - 1$ 。 (x, y) 和 (x', y') 是图像中的一组像素对的坐标,图像中所有像素的坐标集合为 P 。由该图像产生的 GLCM 中 (i, j) 元素可以表示为当像素 (x, y) 的灰度值 $I = i$,与其距离为 d ,与水平线夹角为 θ 的邻近像素 (x', y') 的灰度值 $I' = j$ 时,满足条件的像素对在图像中出现的频次,如式(6)所示。

$$p(i, j, d, \theta) = \frac{\#\{(x, y), (x', y') \in P \mid I = i, I' = j\}}{M \times N} \quad (6)$$

式中: $\#\{\cdot\}$ 代表满足条件的像素对数量。在本文所提方法中,利用暗通道值作为像素的灰度值进行 GLCM 的统计。

由于遥感图像中的大部分云是连续分布的厚云,因此其邻域内像素对之间的暗通道值较一致,变化平缓;而高亮地表由于存在沟壑等原因,可能出现不同亮度区域交错存在的现象,在邻域内暗通道值变化剧烈。这将导致云和高亮地表统计得到的 GLCM 分布具有较大差异,可以利用这一差异进行区分。实际应用中,一般不直接使用 GLCM 作为特征,而是在其基础上计算二次统计量作为特征参数进行下一步的判断。本文主要利用 3 种常见的二次统计量对云和高亮地表进行表征,分别为角二阶矩、对比度和熵。

角二阶矩,又称为能量,反映了像素值分布是否均匀。当图像角二阶矩越大时,代表图像中像素集中在某些像素值上,分布不均匀。其数学表达如式(7)所示。

$$ASM_{d, \theta} = \sum_{i=0}^{L_g-1} \sum_{j=0}^{L_g-1} (p(i, j, d, \theta))^2 \quad (7)$$

对比度,反映了图像的清晰程度与纹理沟纹深浅程度。当对比度较大时,图像较清晰,且纹理沟纹较深。其数学表达如式(8)所示。

$$CON_{d, \theta} = \sum_{i=0}^{L_g-1} \sum_{j=0}^{L_g-1} (i - j)^2 p(i, j, d, \theta) \quad (8)$$

熵,反映了图像中包含信息量。当图像信息量较大时,GLCM 的各个位置元素值分布较平均,此时熵值较大。其数学表达如式(9)所示。

$$Entropy_{d,\theta} = - \sum_{i=0}^{L_g-1} \sum_{j=0}^{L_g-1} p(i,j,d,\theta) \ln p(i,j,d,\theta) \quad (9)$$

从以上 GLCM 二次统计量特征的计算方式可以看到,特征在构建过程中必然会产生二维矩阵作为中间结果,同时其计算需分成两部分进行:首先需要在原始图像中统计特定方向与距离下像素对的出现频次得到 GLCM,其次对 GLCM 中所有元素进行累加。在这一过程中,产生的中间结果数据量 $data_volume$ 和总体计算时间 T 如式(10)和式(11)所示。

$$data_volume = n_{d,\theta} \times L_g^2 \times bit_width \quad (10)$$

$$T = \underbrace{n_{d,\theta} \times M \times N \times T_h}_{\text{共生矩阵统计时间}} + \underbrace{n_{d,\theta} \times L_g^2 \times T_f}_{\text{特征计算时间}} \quad (11)$$

式中: $n_{d,\theta}$ 代表距离 d 以及方向 θ 对应 GLCM 的个数; bit_width 代表 GLCM 中元素的表示位宽; T_h 代表单个像素的统计耗时; T_f 代表在计算 GLCM 二次统计量时单个元素的计算耗时。

通过上述公式可以发现,在统计 GLCM 以及计算其二次统计特征时产生的数据量和计算时间受到原始图像灰度级的严重影响。对于遥感图像而言,像素通常采用 10 位以上的量化,其灰度级超过 1 024,而统计 GLCM 产生的数据量超过 50 Mbit,对于如 FPGA 等片上存储资源具有严格限制的星载处理器将产生巨大的压力,同时通过二维矩阵计算二次统计特征需要较长的时间。现有研究通常在统计 GLCM 时对灰度级进行缩小以改善此问题,但是过度的缩小灰度级将使得图像丧失对场景的精细分辨的能力,因此仍需要对现有 GLCM 二次统计特征的计算方式进行改进,以满足星载应用的需求。

2) GLCM 对角线特征

通过对原始 GLCM 特征的分析可以发现,其计算过程中产生的中间结果数据量与操作数较多,这是由于需要遍历 L_g^2 次才能得到最终结果导致的。因此,计算过程中减少在 GLCM 上的遍历范围,是减少特征计算所需存储空间,提升处理效率的有效途径。对于云和高亮地表而言,由于二者的像素暗通道值普遍较高,且大部分像素暗通道值相接近,这使得二者在 GLCM 中并不是分散分布,而是集中分布在特定的区域中。若仅在该区域遍历 GLCM 元素以求解二次统计特征,则可以在表征纹理特性的同时,有效减少所需存储的数据量与计算产生的操作数。由于大部分云纹理变化较平缓,其内部像素暗通道值表现更一致,因此云图像块在 GLCM 中分布更集中在中心像素 (x,y) 的灰度值 i 与邻近像素 (x',y') 的灰度值 j 相等的 45° 对角线附近,且更容易集中在某些灰度值上;而对于高亮地表,由于纹理变化更剧烈,其内部像素

存在从高亮区域到暗区域的过渡,因此高亮地表图像块在 GLCM 中可能在中心像素 (x,y) 的灰度值 i 与邻近像素 (x',y') 的灰度值 j 的和等于 L_g 的 135° 对角线附近存在。考虑到以上因素,本文设计一种 GLCM 的 45° 和 135° 对角线特征,以代替原始二次统计特征对云和高亮地表进行表征。

为了求解 GLCM 的 45° 对角线角二阶矩特征,首先需要统计该范围内像素对出现频次。给定距离 d 与方向 θ 的像素对,该像素对是否出现在 GLCM 的 45° 对角线范围内的判别函数与出现频次如式(12)和(13)所示。

$$\varphi'(i,j,d,\theta) = \begin{cases} 1, & |i-j| \leq gap_{45} \\ 0, & \text{其他} \end{cases} \quad (12)$$

$$p'(i,j,d,\theta) = \frac{\sum_{x=1}^M \sum_{y=1}^N \varphi'(i,j,d,\theta)}{M \times N} \quad (13)$$

式中: gap_{45} 为可调节参数,定义了对角线范围的大小。

通过式(12)和(13),在以 gap_{45} 定义的 GLCM 的 45° 对角线范围内出现的像素对频次 $p'(i,j,d,\theta)$ 得到统计,而 $p'(i,j,d,\theta)$ 可以表征图像块在 GLCM 上的分布特性。将 $p'(i,j,d,\theta)$ 代替 $p(i,j,d,\theta)$,设计 GLCM 的 45° 对角线角二阶矩特征表达如式(14)所示。

$$ASM_{d,\theta}^{45} = \sum_{i=0}^{L_g-1} (q'(i,d,\theta))^2 = \sum_{i=0}^{L_g-1} \left(\sum_{j=0}^{L_g-1} p'(i,j,d,\theta) \right)^2 \quad (14)$$

可以发现,GLCM 的 45° 对角线角二阶矩实际上是在满足像素对位于 GLCM 的 45° 对角线范围内时,遍历中心像素所有可能出现的值得到的。因此,在其计算过程中,无需统计像素对形成的二维 GLCM,而只需统计中心像素的一维分布直方图。这使得在二次统计特征计算时所需的存储和计算开销得到了极大的降低。同时,该改进特征也继承了原始角二阶矩特征的特点,能够有效表征图像块像素分布是否均匀。由于像素对之间的距离和方向具有不同的选择,设参与统计的像素对距离共有 D 种,方向共有 $\theta_{\max}$ 种,则在所有距离和方向下 45° 对角线角二阶矩特征均值如式(15)所示。

$$ASM' = \frac{1}{d \times \theta_{\max}} \sum_{d=0}^D \sum_{\theta=0}^{\theta_{\max}} ASM_{d,\theta}^{45} \quad (15)$$

参照 45° 对角线角二阶矩的表达方式,可以设计出 45° 对角线对比度特征及其在所有距离和方向下均值如式(16)和(17)所示。

$$CON_{d,\theta}^{45} = \sum_{i=0}^{L_g-1} \left(\sum_{j=0}^{L_g-1} (i-j)^2 p'(i,j,d,\theta) \right) \quad (16)$$

$$CON' = \frac{1}{d \times \theta_{\max}} \sum_{d=0}^D \sum_{\theta=0}^{\theta_{\max}} CON_{d,\theta}^{45} \quad (17)$$

可以看到,GLCM 的 45° 对角线对比度特征计算过程

与角二阶矩类似,同样采用 45° 对角线范围内出现频次 $p'(i,j,d,\theta)$ 代替原始的 $p(i,j,d,\theta)$, 从而实现一维直方图统计,保持对纹理表征能力的同时降低了复杂度。

同理, 45° 对角线熵特征及其在所有距离和方向下均值如式(18)和(19)所示。

$$Entropy_{d,\theta}^{45} = - \left(\sum_{i=0}^{L_g-1} q'(i,d,\theta) \ln q'(i,d,\theta) + q'_{\text{ext}} \ln q'_{\text{ext}} \right) \quad (18)$$

$$Entropy' = \frac{1}{d \times \theta_{\max}} \sum_{d=0}^D \sum_{\theta=0}^{\theta_{\max}} Entropy_{d,\theta}^{45} \quad (19)$$

式中: q'_{ext} 代表对角线范围外像素出现的概率。

通过上式可以发现, 45° 对角线熵特征不仅表征 GLCM 的 45° 对角线范围内的像素暗通道值分布是否均匀,还表征对角线范围内外分布特性。当图像在 GLCM 对角线范围内像素数量较多时,此时对角线范围内外像素数量差异较小,导致熵值较大;反之,熵值较小。

与 GLCM 的 45° 对角线特征设计方法类似,可以通过统计像素对在 GLCM 的 135° 对角线范围内出现频次得到 GLCM 的 135° 对角线特征。该像素对是否出现在 GLCM 的 135° 对角线范围内的判别函数与出现频次如式(20)和(21)所示。

$$\varphi''(i,j,d,\theta) = \begin{cases} 1, & |i+j| \geq L_g - gap_{135}, \\ & |i+j| \leq L_g + gap_{135} \\ 0, & \text{其他} \end{cases} \quad (20)$$

$$p''(i,j,d,\theta) = \frac{\sum_{x=1}^M \sum_{y=1}^N \varphi''(i,j,d,\theta)}{M \times N} \quad (21)$$

式中: gap_{135} 为可调节参数,定义了 135° 对角线范围的大小。利用上式,将 $p''(i,j,d,\theta)$ 代入到二次统计特征的求解公式中,即可得到 GLCM 的 135° 对角线特征。

在本文所提方法中,设置 $D=1$, $\theta_{\max}=4$ 。同时,设计了6种基于 GLCM 的 45° 和 135° 对角线的统计特征,最终得到的特征在统计过程中产生的中间结果数据量 $data_volume'$ 和处理时间 T' 如式(22)和(23)所示。

$$data_volume' = n_{d,\theta} \times 6 \times L_g \times bit_width \quad (22)$$

$$T' = \underbrace{n_{d,\theta} \times M \times N \times T_h}_{\text{共生矩阵统计时间}} + \underbrace{n_{d,\theta} \times L_g \times T_f}_{\text{特征计算时间}} \quad (23)$$

通过式(22)和(23)与式(10)和(11)进行对比可以发现, GLCM 对角线特征相比原有特征在中间结果数据量和特征计算复杂度上均从 $O(L_g^2)$ 变为 $O(L_g)$, 极大的减少了存储需求和计算时间,使得纹理特征能够较容易的应用于资源严重受限的星载处理器平台中。

2 基于FPGA的像素值统计并行加速结构

第1章所提出的基于光谱-改进纹理树状分析的云图分类方法从简单阈值控制算法流程与纹理特征计算复

杂度精简两方面进行优化,使得云图分类方法在具备对复杂场景有效分类的前提下极大的减少了存储占用以及计算操作数,改善了算法的处理效率。然而,通过1.2节对天津法计算过程的介绍以式(23)所示纹理特征总体处理时间,可以发现在图像中对单个像素和像素对的统计时间仍在总体处理时间中占有较大比重。由于现有宽幅遥感图像通常具有庞大的像素数量,如果采用传统的逐像素顺序统计的方式,则需要耗费大量的统计时间,严重影响算法整体处理效率。已有方法证明,结合算法特点,利用FPGA构造高并行性计算结构,对多个数据进行同步处理可以有效提升处理效率^[25-26]。借鉴这一想法,本文在所提出的云图分类方法基础上,进一步提出其对应的计算结构以实现处理加速。

考虑到算法中包含的不同类型操作,本文采用基于FPGA的片上系统芯片构建计算系统。片上系统芯片主要包含处理器系统(processing system, PS)和可编程逻辑(programmable logic, PL)两部分,其中PS部分为ARM(advanced RISC machine)微处理器单元,擅长处理控制密集型任务,因此在该计算系统中将控制较多的子图切分处理和计算操作数较少且需要循环控制的大津法阈值计算等任务部署在PS中。而对于可编程逻辑PL,即FPGA中,则设计一个专门面向像素值统计的计算加速结构,以提升大规模像素统计时的处理效率。所提云图分类算法对应计算系统如图2所示。




图2 云图分类方法计算系统

Fig. 2 The computing system for cloud image classification

该计算系统处理流程为:1) 宽幅遥感图像切分为若干个子图,并通过AXI-Stream片上总线依次从PS输入到PL的加速结构中;2) 将输入到PL中的子图再划分为R个部分,并分别用R个直方图统计与特征提取单元进行处理;3) 再求和得到整个子图的统计结果。由于R个

像素同时进行统计,因此统计时间将减小为原来的 $1/R$ 。最后,将统计结果返回 PS 中,完成整体算法对子图的分类型。

像素值统计并行加速结构细节设计如图 3 所示。




图3 像素值统计并行加速结构

Fig. 3 The parallel acceleration architecture for pixel statistics

子图进入 PL 后,取其中 K 个图像块进行缓存,且每个图像块再取 S 行像素,利用 S 个直方图统计单元,参照式(2)、(12)、(13)、(20)和(21)进行分别处理。因此,本文所提出的并行加速结构每次对 K 个图像块中共 $K \times S$ 个像素进行同步统计,即 $R = K \times S$ 。在同步统计多个像素后,将单个图像块对应的 S 个统计结果输入求和单元中,即可得到该图像块 S 行像素合计统计结果。假设一幅子图中包含 U 个图像块,每个图像块包含 V 行数据,则以上像素统计过程需要循环迭代 $(U/K) \times (V/S)$ 次,并累加所有结果,才可得到图像块对应的 GLCM 的对角线范围内像素对出现频次 $p'(i, j, d, \theta)$ 和 $p''(i, j, d, \theta)$,以及像素直方图统计结果 p_i 。之后, $p'(i, j, d, \theta)$ 和 $p''(i, j, d, \theta)$ 将进入 GLCM 对角线特征计算单元以求解 GLCM 对角线特征,且所有图像块的 p_i 结果将进行求和以获得子图的灰度直方图。所有图像块的 GLCM 对角线特征与子图的灰度直方图将返回 PS 中进行后续处理。通过以上描述可以看到,并行加速结构占用的缓存资源与加速性能与并行参数 K 和 S 直接相关。因此,需要在实验中设置合适的 K 和 S 参数。

3 实验验证与评估

3.1 实验目的

本实验旨在验证本文所提云图分类方法在云和地表图像分类精度与算法计算复杂度方面所具备的综合优势,重点与精度较高的云图分类方法相比较以验证所提方法降低计算过程中产生的中间结果数据量以及操作数的能力。此外,进一步测试在加入所提并行加速结构后,本文方法在处理效率上的提升。

3.2 实验方案

为实现上述实验目的,设置实验方案如图 4 所示。




图4 实验详细设计

Fig. 4 The detailed experimental design

本实验主要包含两部分内容,分别为云图分类算法测试与算法计算结构测试。在云图分类算法测试阶段,首先进行 GLCM 对角线特征参数选择实验,通过 gap_{45} 和 gap_{135} 的变化观察 GLCM 对角线特征对云和高亮地表图像块的区分能力,从而选择合适参数。其次,将选择好的参数带入到云图分类方法中,进一步测试算法整体对测试数据的精度表现以及算法的计算复杂度。在算法计算结构测试阶段,首先需要对基于 FPGA 的并行加速结构中的并行度参数 K 和 S 进行测试,选择使得加速效果最佳且缓存占用小于总体片上缓存的 K 和 S 作为最佳并行度参数。其次,基于此完成计算系统设计,利用测试数据测试加入该像素值统计并行加速结构后系统的加速性能。

为实现上述验证方案,在云图分类方法测试时采用通用处理器 i7-12700H 作为测试平台,软件平台与环境为 PyCharm 2021.3 和 Python 3.7。而对于计算结构测试,采用 Zynq 异构片上系统芯片 XC7Z100-2FFG900 为核心的硬件平台开展实验。为了对比分析 FPGA 计算结构的加速性能,本文还利用 Zynq 中自带的 Cortex-A9 ARM 处理器对算法整体进行部署。Cortex-A9 微处理器在云检测等在轨任务中具有广泛的应用,其工作主频为 666.67 MHz,内部含有 256 KB 片上 SRAM,且外挂 1 GB DDR3 存储,工作时功耗低于 2 W,可以为算法提供充足的存储空间与较强的处理性能。

3.3 实验数据

为完成上述实验方案,本文采用在云检测领域常用的 Landsat 8 图像和高分-2 图像作为测试数据。

1) Landsat 8 测试图像:该图像来自美国陆地资源卫星。其成像仪包含 9 个光谱通道,图像空间分辨率为 30 m。为了减小设计的难度,利用开源数据集 38-Cloud 构建测试数据^[27]。选择两幅包含地表场景较多的宽幅图像进行测试,且仅利用图像的可见光通道。图像中的

地表包含水面、植被、裸露的土地、山脉和冰雪等不同的场景。将宽幅图像切割成多个 384×384 的子图,利用这些子图做分类。对于这些子图中是否含云,参考典型在轨云检测研究文献[28]的方法对图片进行标注。在该研究中,通过计算云像素在总体像素中所占百分比对图片进行分类,当云像素占比超过一定值时则认为该图片中有云。在文献[28]中,这一比例为 70%,即云像素超过 70% 时认为该图片含云,否则为非云图片。对于本文所用数据,由于含有云像素数量较少,如果以 70% 比例定义图片类别,将造成保留的含云图片数量过少,且类型大多为连续的厚云。为了增加云图数量,同时丰富云的类型,本文采用更严格的 10% 比例进行图片类别判断,即当云像素超过所有像素的 10% 时将子图看作含云图片。基于此,宽幅遥感图像共切割 904 张子图,其中非云子图 779 张,含云子图 125 张。

2) 高分-2 测试图像:该图像通过中国高分 2 号卫星进行采集。其成像仪包含可见光与近红外在内 4 个光谱通道,图像空间分辨率为 2 m。利用开源数据集 AIR-CD 构建测试数据^[29]。与 Landsat 8 图像类似,选择两幅包含地表场景较多的宽幅图像进行测试,且在测试时仅利用可见光通道。图像中的地表包含水面、森林、城市和冰雪等不同的场景。同样将宽幅图像切割成多个 384×384 的子图,将含云像素超过 10% 的子图看作有云,因此所选择的宽幅图像共切割为 720 张子图,其中非云子图 577 张,含云子图 143 张。

3.4 实验评价指标与对比方法

本文主要采用两类不同的评价指标对所提方法进行评价。在精度方面,采用常用的总体精度 (overall accuracy, OA) 进行评价。该指标主要从云和地表总体分类准确性的角度对算法进行评价,如式 (24) 所示。

$$OA = \frac{\sum_{i=1}^c pred_{ii}}{\sum_{i=1}^c \sum_{j=1}^c pred_{ij}} \quad (24)$$

式中: $pred_{ij}$ 代表实际属于第 i 类,检测为第 j 类的子图数量; c 代表子图所有类别的数量。

为了更好的评价算法对于云的分类性能,在精度测试中还采用云的误检率 (false positive rate, FPR) 作为指标。本文实验中,将有云子图看作正例,将非云子图看作负例,因此测试结果可分为 4 类,分别为真正例 (true positive, TP), 真反例 (true negative, TN), 假正例 (false positive, FP) 以及假反例 (false negative, FN), 而 FPR 计算如式 (25) 所示。

$$FPR = \frac{FP}{FP + TN} \quad (25)$$

除精度测试外,本文还对算法计算复杂度及其对应

的加速结构处理效率进行测试。在计算复杂度方面,主要对算法计算过程中产生的操作数和中间结果数据量进行统计。由于现有面向在轨的云图分类方法计算类型差异较大,为了公平对比,利用算法中包含的操作数来衡量不同算法的计算复杂性,其单位为 GOPs。本文实验将一次四则运算、对数操作、指数操作以及像素值的统计均视为一次操作。此外,本章实验还对算法产生的中间结果数据量进行比较 (单位为 M, $1 \text{ M} = 10^6$)。其定义为算法从输入图像到输出预测标签中间所产生所有数据总量。在加速结构处理效率测试方面,采用在计算系统中完成一次全部子图的统计产生的时间作为评价指标 (单位为 s)。

为了充分测试算法在精度和计算复杂度方面的综合性能,选择以下 4 种图像分类方法作为对比实验,其中前两种专为在轨云检测应用设计,具有计算简单、占用存储资源少的特点;而后两种方法提取更复杂的特征,对云和地表区分性能更强,但同时计算复杂度更高:

1) 遥感图像实时云判方法 (real time cloud detection, RTCD)^[6]。该方法利用均值、方差、边缘和熵等简单统计特征作为最小距离分类器的判据,以区分含云和非云图像块。

2) Cloudsatnet-1 实时云检测网络^[7]。该网络内部卷积层仅为 10 层,同时通过量化等方法对网络进行轻量化改进,其存储占用较少。

3) 基于多特征学习 SVM 的云检测方法 (multi-feature based SVM for cloud detection, MFSVM)^[13]。该方法以灰度梯度共生矩阵和分形维数等复杂纹理特征为基础训练 SVM 分类器,实现对云图的分类,对含有不同类型云的复杂场景具有较好的检测性能。

4) 轻量级分类网络 MobileNetV3^[30]。该方法为当前最典型的一种实时处理的图像分类网络,在云检测领域具有广泛应用。相比 CloudScout,该方法具有更多的网络层数和通道数,因此具有更强的特征提取能力。

3.5 实验结果与分析

1) 云图分类精度及计算复杂度实验结果

(1) GLCM 对角线特征参数选取

为了选择出能够有效区分云和高亮地表纹理特性的特征参数 gap , 在本实验中利用多个尺寸为 48×48 的云和高亮地表图像块,在不同 gap 取值下进行 GLCM 对角线特征计算,选择能够最大程度区分云和地表的 gap 参数。本文利用可分离度 (separable degree, SD) 表征对角线特征对云和地表的区分能力,如式 (26) 所示。

$$SD = \sqrt{\frac{(\mu_{cloud} - \mu_{land})^2}{\sigma_{cloud} \times \sigma_{land}}} \quad (26)$$

式中: μ_{cloud} 和 μ_{land} 代表云和地表在同一特征表征下各自的均值; σ_{cloud} 和 σ_{land} 代表云和地表在同一特征表征下各自的标准差; SD 为无量纲指标。

利用 Landsat 8 测试图像,首先对 GLCM 对角线角二阶矩特征进行测试。在 $[0, 256]$ 范围对 gap_{45} 和 gap_{135} 取值,测试不同取值时在本文所提出的 GLCM 的 45° 和 135° 对角线角二阶矩特征表征下云和高亮地表的 SD 指标变化曲线,如图 5 和 6 所示。




图 5 GLCM 的 45° 对角线角二阶矩表征下 SD 变化曲线
Fig. 5 Curve of SD under the 45° diagonal angular second moment of GLCM




图 6 GLCM 的 135° 对角线角二阶矩表征下 SD 变化曲线
Fig. 6 Curve of SD under the 135° diagonal angular second moment of GLCM

从图 5 和 6 可见, GLCM 的 45° 对角线范围内云和高亮地表角二阶矩特征的 SD 随参数 gap_{45} 增大呈现先增大后减小,最后保持不变的趋势。这可能是由于厚云内部像素暗通道值比较一致,因此位于对角线范围内的像素更多,导致云的角二阶矩特征均值普遍大于高亮地表,使得 SD 增大;而 gap_{45} 超出一定值后,云和高亮地表在 45° 对角线范围内像素数量差距减小直至不变,因此 SD 也逐渐减小。此外, GLCM 的 135° 对角线范围内统计的云和高亮地表角二阶矩的 SD 随 gap_{135} 增大呈现先减小后增大到不变的趋势。这可能是由于在 gap_{135} 较小时,高亮地表和云在对角线范围内的像素数量均较少,使得两者标准差都较小,从而 SD 较大。随着 gap_{135} 增大,两者在 135° 对角线范围内像素数量增多,标准差增大,导致 SD 下降。当 gap_{135} 增大到一定范围后,厚云在对角线范

围内更集中,因此其角二阶矩较大,使得 SD 回升。依照 SD 变化,可选择合适的 gap_{45} 和 gap_{135} 参数。

选择适当的参数后,利用 GLCM 的 45° 和 135° 对角线角二阶矩特征进行表征与利用原始 GLCM 角二阶矩特征进行表征的云和地表 SD 对比如表 1 所示。

表 1 GLCM 对角线角二阶矩与原始角二阶矩对比 Table 1 Comparison of the diagonal angular second moment and original angular second moment of GLCM	
方法	SD
45° 对角线角二阶矩	0.49
135° 对角线角二阶矩	0.50
原始角二阶矩	0.20

从表 1 结果中可以看到,采用对角线角二阶矩特征表征的云和地表 SD 均大于原始角二阶矩特征表征下的云和地表的 SD,这表明本文所提出的对角线角二阶矩特征相对于原始角二阶矩特征对于厚云和高亮地表区分能力更强。

之后,对 GLCM 对角线对比度特征进行测试。同样,在 $[0, 256]$ 范围对 gap_{45} 和 gap_{135} 取值,测试 GLCM 的 45° 和 135° 对角线对比度特征表征下云和高亮地表的 SD 变化曲线,如图 7 和 8 所示。




图 7 GLCM 的 45° 对角线对比度表征下 SD 变化曲线
Fig. 7 Curve of SD under the 45° diagonal contrast of GLCM




图 8 GLCM 的 135° 对角线对比度表征下 SD 变化曲线
Fig. 8 Curve of SD under the 135° diagonal contrast of GLCM

通过图 7 和 8 结果可以发现, GLCM 的 45° 对角线范围对比度特征表征下的云和高亮地表可在一定范围内增大, 虽然云在此范围内分布概率较大, 但更贴近对角线分布。根据式 (16), 云对比度接近 0, 而高亮地表对比度更大, 使得两者 SD 变大。达到一定范围后, 随着两者在 45° 对角线范围内分布数量增多, 对比度差异减小。此外, GLCM 的 135° 对角线范围内对比度特征表征下的云和高亮地表 SD 随 gap_{135} 增大呈现先减小后增大的趋势。这是由于在 135° 对角线范围内高亮地表像素数量多于厚云, 且这些像素较多远离对角线, 因此其对比度大于云, SD 较大。而随着 gap_{135} 增大, 在 135° 对角线范围内云像素对出现频次增加, 使得云与高亮地表在对比度特征的 SD 减小。而云集中在某一暗通道值附近, 这使得 gap_{135} 增大到一定范围时, 云像素对在对角线范围内出现频次急剧增加, 其对比度超过地表, SD 一定程度变大。

选择适当的参数后, 利用 GLCM 的 45° 和 135° 对角线对比度特征进行表征与利用原始 GLCM 对比度特征进行表征的云和地表 SD 对比如表 2 所示。

表 2 GLCM 对角线对比度与原始对比度对比	
Table 2 Comparison of the diagonal contrast and the original contrast of GLCM	
方法	SD
45° 对角线对比度	2.11
135° 对角线对比度	1.62
原始对比度	0.80

从表 2 结果中可以看到, 与角二阶矩结果类似, 采用本文所提对角线对比度特征进行表征的云和高亮地表 SD 均大于原始 GLCM 对比度表征下的云和地表的 SD, 这表明本文所提对比度特征对于厚云和高亮地表区分能力更强。

最后, 对 GLCM 对角线熵特征进行测试。同样, 在 $[0, 256]$ 范围对 gap_{45} 和 gap_{135} 取值, 测试 GLCM 的 45° 和 135° 对角线熵特征表征下云和高亮地表的 SD 变化曲线, 如图 9 和 10 所示。

可以看到, GLCM 的 45° 对角线范围内统计得到熵表征的云和高亮地表的 SD 随 gap_{45} 增大呈现先增大后减小至不变的趋势。这是由于当 gap_{45} 较小时, 厚云在 45° 对角线范围内外像素分布更平均, 熵值较大。而高亮地表由于像素集中分布在对角线范围外, 熵值普遍较小。因此, 两者 SD 有明显的增大。随着 gap_{45} 增大, 高亮地表在 45° 对角线范围内各暗通道级上的分布更均匀, 使得熵值增大, 厚云与高亮地表熵特征均值差距减小, SD 减小。而对于 GLCM 的 135° 对角线范围统计得到的熵特征, 可以发现厚云和高亮地表的 SD 一直在较低的水平,




图 9 GLCM 的 45° 对角线熵表征下 SD 变化曲线
Fig. 9 Curve of SD under the 45° diagonal entropy of GLCM




图 10 GLCM 的 135° 对角线熵表征下 SD 变化曲线
Fig. 10 Curve of SD under the 135° diagonal entropy of GLCM

这可能是由于云和高亮地表在此对角线范围内分布较类似, 因此 SD 较低。

选择适当的参数后, 利用 GLCM 的 45° 和 135° 对角线熵特征进行表征与利用原始 GLCM 熵特征进行表征的云和地表 SD 对比如表 3 所示。

表 3 GLCM 的对角线熵与原始熵对比	
Table 3 Comparison of the diagonal entropy and the original entropy of GLCM	
方法	SD
45° 对角线熵	1.80
135° 对角线熵	0.44
原始熵	0.67

从表 3 结果中可以看到, 与原始 GLCM 熵特征表征得到的云和高亮地表 SD 相比, 采用本文所提 GLCM 的 45° 对角线熵特征进行表征时 SD 更大, 说明其对云和高亮地表区分能力较强。

(2) 不同方法精度与计算复杂度对比
在本实验中, 为了进一步验证所提 GLCM 对角线特

征对算法精度和计算复杂性的影响,在保留整体算法树状分析框架的基础上,采用不同的 GLCM 特征构建不同方案进行对比。第 1 种方案为不采用任何 GLCM 特征,而将所有阈值大于 th_2 的图像块直接看作为云;第 2 种方案为采用原始 GLCM 统计的特征作为基础,训练 K-means 分类器。利用 Landsat 8 数据集进行测试,不同方案下算法测试精度与计算产生的操作数和中间结果数据量如表 4 所示。

表 4 Landsat 8 数据集测试下加入不同 GLCM 特征子图分类方法对比结果

Table 4 Comparison of sub-image classification methods with different features of GLCM in Landsat 8 dataset

方法	OA/%	FPR/%	操作数/GOPs	数据量/M
无 GLCM	83.19	16.05	0.68	<0.01
原始 GLCM	85.51	13.35	8.80	16.91
本文方法	85.84	13.74	1.25	0.20

从表 4 结果可以发现,在无 GLCM 特征参与处理的情况下,由于不需要遍历图像块中所有像素以统计直方图,计算产生的操作数和中间结果数据量最少。然而,这种处理方式将有较多的非云图像被错判为云,造成了 OA 偏小,FPR 指标偏大。以上结果表明了利用 GLCM 特征进行纹理表征可以一定程度弥补光谱阈值的局限性,从而提高对云和地表的分类性能。

此外,对比本文所提出的 GLCM 对角线特征构建的方法与利用原始 GLCM 特征构建的方法,本文方法在 OA 指标上相对较高,而在云的误检上仅比采用原始 GLCM 特征方法高 0.39%,这表明本文所提出的 GLCM 对角线特征可实现与原始 GLCM 对角线特征近似的对云和高亮地表区分能力。且更值得注意的是,采用原始 GLCM 特征由于需要统计二维矩阵,因此整体计算产生的操作数和中间结果数据量远大于本文所提出的方法。利用本文构建的 GLCM 对角线特征设计的子图分类方法在计算操作数上相较原始 GLCM 特征构建的方法减少 85.80%,在中间结果数据量上减少了 98.82%。这表明本文所提出的特征处理时占用的存储和计算资源将更少,消耗的时间更低,更容易达到在轨高速处理的目标。

利用 3.4 节中介绍的对比实验方法,对所提出的子图分类方法的精度和计算复杂性等指标进行分析,得到的对比结果如表 5 所示。


通过分析以上结果可以发现,在 Landsat 8 数据测试下,与专用于星载处理且计算过程简单的 RTCD 和 Cloudsatnet-1 方法相比,本文方法在整体精度 OA 和云误检率 FPR 等方面均具有明显优势,且本方法计算操作数较少,与计算最简单的 RTCD 方法相比操作数仅超过


表 5 Landsat 8 数据集测试下不同子图分类方法对比结果
Table 5 Comparison of sub-image classification methods in Landsat 8 dataset

方法	OA/%	FPR/%	操作数/GOPs	数据量/M
RTCD	83.08	16.94	1.24	0.02
Cloudsatnet-1	83.30	15.15	44.12	0.66
MFSVM	84.85	15.28	32.80	4.66
MobileNetV3	84.62	16.30	328.15	4.74
本文方法	85.84	13.74	1.25	0.20

0.81%。这是由于本文方法通过两级全局自适应阈值进行树状分支控制,实现了对不同类型地表在单独分支内进行处理,有效减少了干扰,同时减少了复杂纹理特征的提取次数,并利用计算优化的 GLCM 对角线特征代替原有的 GLCM 特征,在保证计算产生的操作数与数据量较小的前提下提升了对高亮地表的检出能力,兼顾了云判精度与计算效率。此外,与特征提取更丰富的 MFSVM 和 MobileNetV3 方法相比,本文方法在精度方面更具竞争力的同时,计算复杂度上也具有更大的优势。与 MFSVM 相比,计算产生的操作数减少了 96.19%,中间结果数据量减少了 95.71%。而与 MobileNetV3 相比,计算产生的操作数减少了 99.62%,在中间结果数据量上减少了 95.78%。以上结果表明所提方法通过对计算流程和特征求解的改进,大幅度的减少了计算产生的操作数与中间结果数据量,且对于云和地表保持较强的检测性能,更符合在轨有限资源条件下遥感图像高效处理的需求。

为了更直观地展示不同方法对云和非云图像的分类能力,本文进一步给出不同方法在 Landsat 8 数据集上测试的混淆矩阵结果,如图 11 所示。混淆矩阵每一列代表了图像实际所属类别,每一行则代表该方法检测的图片类别。





(e) 本文方法结果
(e) The proposed method results

图 11 LandSat 8 数据集下不同方法混淆矩阵
Fig. 11 Confusion matrix of different methods in LandSat 8

通过对图 11 的分析可以发现,与对比实验方法相比,本文方法对实际类别为非云的图像检测正确的数量较多,说明其对于非云地表具有较强的检出能力,这使得云的误检较低。而对于类别为云的图像正确检测的数量略低于特征提取更丰富的 MFSVM 和 MobileNetV3 方法,这主要是由于数据集内包含暗通道值较低的薄云图像,通过两级全局阈值进行分支处理时易造成错误分类所导致的。暗通道值较低的薄云对算法的影响可以通过图 12 和 13 进行更直观的展示。




图 12 薄云图像暗通道
Fig. 12 The dark channel histogram of the thin cloud image




图 13 厚云图像暗通道
Fig. 13 The dark channel histogram of the thick cloud image

其中,图 12 为未检出的薄云图像暗通道直方图,图 13 为厚云暗通道直方图,图中竖线代表全局阈值 th_1 。由于可见光可以透过薄云对地表物体进行反射,因此在可见光遥感图像中薄云区域通常是‘半透明’的,这使得薄云的暗通道值与地表近似。通过图 12 和 13 的对比可以发现,薄云中像素暗通道值大部分集中在小于全局阈值的位置,因此易被判断为地表;而厚云图像则有更多像素在大于全局阈值的位置,易得到正确的分类。对薄云的误检是影响本文所提方法精度的主要问题,但由于薄云在遥感图像中占比较低,因此利用阈值法计算复杂度低的特点可以对遥感图像中大部分云有效检出的同时提高算法整体的处理效率。

为了进一步验证所提方法的泛用能力,采用高分-2 数据集重复以上实验过程。利用高分-2 数据集进行测试时,不同 GLCM 特征方案下算法测试精度与计算产生的操作数和中间结果数据量如表 6 所示。

表 6 高分-2 数据集测试下加入不同 GLCM 特征子图分类方法对比结果

Table 6 Comparison of sub-image classification methods with different features of GLCM in Gaofen-2 dataset				
方法	OA/%	FPR/%	操作数/GOPs	数据量/M
无 GLCM	85.14	13.00	0.55	<0.01
原始 GLCM	92.22	5.20	6.87	16.91
本文方法	92.08	5.20	0.87	0.20

可以发现,高分-2 数据集测试下结果与 Landsat 8 数据测试下结果类似。在无 GLCM 特征参与处理的情况下,计算产生操作数与数据量较少,但精度偏低。而与原始 GLCM 特征相比,采用本文所提改进特征,在云的误检上保持一致的同时,计算产生的操作数减少了 87.34%,中间结果数据量减少了 98.82%,表明了利用本文所提出的 GLCM 对角线特征进行纹理表征时在高分-2 数据集上同样具有计算优势。

利用 3.4 节中介绍的对比实验方法,采用高分-2 数据集进行测试,得到的对比结果如表 7 所示。

表 7 高分-2 数据集测试下不同子图分类方法对比结果
Table 7 Comparison of sub-image classification methods in Gaofen-2 dataset

方法	OA/%	FPR/%	操作数/GOPs	数据量/M
RTCD	87.92	8.84	0.99	0.02
Cloudsatnet-1	91.36	6.59	35.14	0.66
MFSVM	93.06	6.07	26.12	4.66
MobileNetV3	94.58	3.99	261.36	4.74
本文方法	92.08	5.20	0.87	0.20

如表 7 结果所示,在高分-2 数据集测试下,也可看到本文所提方法在精度和计算复杂度方面的综合优势。与专用于星载处理且计算过程简单的 RTCD 和 Cloudsatnet-1 相比,所提方法精度较高,且计算产生的操作数和数据量少。而与 MFSVM 和 MobileNetV3 相比,尽管在 OA 上表现略低,但在计算复杂度方面的优势更明显。与 MFSVM 相比,计算产生的操作数减少了 96.67%,中间结果数据量减少了 95.71%。而与精度表现最好的 MobileNetV3 相比,本文方法操作数减少了 99.67%,在数据量上减少了 95.78%。通过对未检出的云图像类别的观察可以发现,与 Landsat 8 数据集类似,在高分-2 数据集上也有较多薄云图像难以检出,从而导致总体精度降低。但综合以上精度和计算复杂性指标来看,本文所提方法在高分-2 数据集中同样保持了较高的分类性能,且计算复杂度较低。

2) 基于 FPGA 的加速结构性能验证

本实验首先对并行参数 K 和 S 进行不同取值,观察计算结构处理延时与所占片上存储资源的变化情况,并选择合适的参数,使得占用资源不超过 FPGA 总的片上缓存前提下,达到最小的处理延时。由于一张子图可切分为 64 个图像块,为简化设计,参数 K 通过集合 $\{1, 2, 4, 8, 16\}$ 进行取值, S 通过集合 $\{1, 2, 3, 4, 6, 8, 12\}$ 进行取值。本实验通过 Vivado HLS 软件进行加速结构设计与测试,通过处理时延评价结构处理效率,其代表处理一张子图所需工作时钟个数;同时,利用加速结构使用的块随机存取存储单元 (block random access memory, BRAM) 占总的 BRAM 的百分比评价构建加速结构存储资源使用率,如图 14 和 15 所示。




图 14 处理时延随并行参数 K 和 S 变化
Fig. 14 Bar chart of processing latency vs. parallel parameters K and S

通过实验结果可以看到,当参数 K 和 S 的取值越大时,处理时延越少。这表明利用并行处理方式可有效提升处理效率,且并行度设置越大处理延时越短。然而,随着并行度的增加,加速结构所占用的资源也随之升高。同时可以看到,相较而言,参数 K 对处理时延的影响更




图 15 BRAM 随并行参数 K 和 S 变化
Fig. 15 Bar chart of BRAM vs. parallel parameters K and S

大。考虑到存储占用等方面的影响,本文选择参数 K 取值为 16, S 取值为 1。

利用上述最优参数构建并行加速结构,为验证该结构对算法的加速性能,以高分-2 数据中的宽幅遥感图像为测试数据,通过将所提算法仅部署在 Zynq 片上系统芯片的 ARM 单元作为对比方法。此外,还进一步与典型在轨云图分类方法结果进行对比,验证本文方法的性能优势。不同方法处理时间对比如表 8 所示。

表 8 不同加速方法处理时间对比

Table 8 Comparison of processing time of different acceleration methods			
方法	加速平台	图像尺寸/pixel	处理时间/s
本文方法	仅 ARM	7 300×6 908	28.61
	ARM+FPGA	7 300×6 908	1.16
Cloudsatnet-1 ^[7]	ARM+FPGA	512×512	0.07

通过表 8 结果可以看到,本文算法结合所提出的并行加速结构,可以在 1.20 s 内完成对一幅 7 300×6 908 pixels 尺寸图像的处理,每秒可处理 43.47×10^6 pixels。相较于不采用 FPGA 并行加速,仅利用 ARM 进行处理的方案,处理时间缩短了 95.95%。这表明了采用本文所提计算加速结构可以实现良好的加速效果。而典型在轨云图分类加速方法尽管也利用了 FPGA 加速能力,但每秒处理像素仅为 3.74×10^6 ,表明本文所提加速结构对在轨云图分类效率提升方面有较大帮助。

4 结 论

针对现有在轨云图分类方法利用复杂纹理特征对云和地表进行表征时,易产生计算复杂、中间结果数据量大等问题,本文提出一种光谱-改进纹理特征树状分析的云图分类算法,并根据其特点设计了一种基于 FPGA 的并行加速结构。该算法通过两级全局自适应阈值进行树状

分支控制,对暗通道值较小的图像实现快速检出,有效减少复杂纹理特征计算次数。同时,构建了一种新颖的GLCM对角线特征,以代替原始特征进行纹理表征,在保持对云和高亮地表区分能力的前提下极大减少了计算操作数和数据量。此外,根据像素值统计方法的计算特性,利用FPGA并行处理特点进行加速结构设计,进一步提高了算法整体的处理效率。实验结果显示,本文云图分类算法在精度和计算复杂度上可获得综合优势,且占用存储资源少的特点使其在FPGA上可以构建较大并行度的加速结构,实现对算法的快速处理,为在轨实现云图分类提供了良好的基础。

然而,本文方法对于薄云的检测仍有一定的局限性。通过实验分析可知,这主要是由于薄云暗通道较低,易被阈值法误判为地表所导致的。因此,在未来的研究中将考虑从频率和稀疏性的角度,对薄云区域进行针对性增强,以提高其与地表的区分能力。同时,将构建如小波和分形维数等其他类型特征,以丰富算法对云和地表的表征能力。

参考文献

- [1] 刘子力, 杨家俊, 王文静, 等. 遥感图像云检测方法综述[J]. 中国空间科学技术, 2023, 43(1): 1-17.
LIU Z L, YANG J J, WANG W J, et al. Cloud detection methods for remote sensing images: A survey [J]. Chinese Space Science and Technology, 2023, 43(1): 1-17.
- [2] MEONI G, MARTENS M, DERKSEN D, et al. The OPS-SAT case: A data-centric competition for onboard satellite image classification[J]. *Astrodynamics*, 2024, 8(4): 507-528.
- [3] KHALIL I, CHANOUI M A, ISMAILI Z E A A, et al. Lightweight U-Net based on depthwise separable convolution for cloud detection onboard nanosatellite[J]. *The Journal of Supercomputing*, 2024, 80(18): 26308-26332.
- [4] 冯琳, 宋文强, 徐伟. 一种地基云图分类算法及硬件加速实现[J]. 电子测量与仪器学报, 2025, 39(2): 21-31.
FENG L, SONG W Q, XU W. Hardware acceleration implementation of a ground-based cloud image classification algorithm [J]. *Journal of Electronic Measurement and Instrumentation*, 2025, 39(2): 21-31.
- [5] 彭宇, 姬森展, 于希明, 等. 语义分割网络的FPGA加速计算方法综述[J]. 仪器仪表学报, 2021, 42(9): 1-12.
- [6] 闫宇松, 龙腾. 遥感图像的实时云判技术[J]. 北京理工大学学报, 2010, 30(7): 817-821.
YAN Y S, LONG T. Real-time cloud detection in optical remote sensing image [J]. *Transactions of Beijing Institute of Technology*, 2010, 30(7): 817-821.
- [7] PITONAK R, MUCHA J, DOBIS L, et al. Cloudsatnet-1: FPGA-based hardware-accelerated quantized CNN for satellite on-board cloud coverage classification [J]. *Remote Sensing*, 2022, 14(13): 3180.
- [8] VITOLO P, FASOLINO A, LIGUORI R, et al. Real-time on-board satellite cloud cover detection hardware architecture using spaceborne remote sensing imagery[C]. *Real-time Processing of Image, Depth, and Video Information*, 2024: 128-134.
- [9] CRATERE A, FARISSI M S, CARBONE A, et al. Efficient FPGA-accelerated convolutional neural networks for cloud detection on CubeSats [J]. *IEEE Journal on Miniaturization for Air and Space Systems*, 2025, 6(3): 187-197.
- [10] KIM J H, KIM Y, CHO D H, et al. On-orbit AI: Cloud detection technique for resource-limited nanosatellite[J]. *International Journal of Aeronautical and Space Sciences*, 2025, 26(4): 1975-1988.
- [11] SHANG H ZH, LETU H, XU R, et al. A hybrid cloud detection and cloud phase classification algorithm using classic threshold-based tests and extra randomized tree model[J]. *Remote Sensing of Environment*, 2024, 302: 113957.
- [12] ZHONG B, TANG X, LUO X B et al. A texture-enhanced deep learning network for cloud detection of GaoFen/WFV by integrating an object-oriented dynamic threshold labeling method and texture-feature-enhanced attention module[J]. *Remote Sensing*, 2025, 17(10): 1677.
- [13] ZHANG W D, JIN S L, ZHOU L, et al. Multi-feature embedded learning SVM for cloud detection in remote sensing images[J]. *Computers and Electrical Engineering*, 2022, 102: 108177.

- [14] LI Y L, WU Y H, LI J, et al. A machine learning algorithm using texture features for nighttime cloud detection from FY-3D MERSI L1 imagery[J]. *Remote Sensing*, 2025, 17(6): 1083.
- [15] TANDULE C R, GOGOI M M, BABU S S. Improved cloud screening of OceanSat-3 OCM-3 satellite imagery using machine learning algorithm[J]. *Remote Sensing Applications: Society and Environment*, 2025, 37: 101481.
- [16] SONG W X, JIA SH L, LIU T J, et al. Hierarchy clustering for cloud detection assisted by spectral features of ground covers[J]. *Remote Sensing*, 2026, 18(5): 698.
- [17] 郭玥, 于希明, 王少军, 等. 遥感图像云检测的多尺度融合分割网络方法[J]. *仪器仪表学报*, 2019, 40(6): 31-38.
- GUO Y, YU X M, WANG SH J, et al. Cloud detection in remote sensing images with multilevel scale fused network[J]. *Chinese Journal of Scientific Instrument*, 2019, 40(6): 31-38.
- [18] DONG J W, WANG Y H, YANG Y, et al. MCDNet: Multilevel cloud detection network for remote sensing images based on dual-perspective change-guided and multi-scale feature fusion[J]. *International Journal of Applied Earth Observation and Geoinformation*, 2024, 129: 103820.
- [19] FAN N M, LI D R, PAN J, et al. ANNet: Asymmetric nested network for real-time cloud detection in remote sensing[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2024, 62: 5650914.
- [20] XU X Y, HE W, XIA Y, et al. TANet: Thin cloud aware network for cloud detection in optical remote sensing image[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2025, 63: 5611416.
- [21] PANG SH L, LI ZH Q, SUN L, et al. Enhancing cloud detection across multiple satellite sensors using a combined swin transformer and UPerNet deep learning model[J]. *Remote Sensing of Environment*, 2026, 334: 115206.
- [22] REN ZH Y, WENG L G, XIA M, et al. MCINet: Multi-attentive cross-level interaction network for cloud and snow segmentation[J]. *Journal of Applied Remote Sensing*, 2025, 20(2): 021404.
- [23] HE K M, SUN J, TANG X OU. Single image haze removal using dark channel prior[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2010, 33(12): 2341-2353.
- [24] OTSU N. A threshold selection method from gray-level histograms[J]. *IEEE Transactions on Systems, Man, and Cybernetics*, 1979, 9(1): 62-66.
- [25] BARROS W K, DIAS L A, FERNANDES M A. Fully parallel implementation of Otsu automatic image thresholding algorithm on FPGA[J]. *Sensors*, 2021, 21(12): 4151.
- [26] WU H, SONG H L, LIU N, et al. Efficient and high accuracy 2-D DCT and IDCT architecture for image compression based on improved CORDIC[J]. *Instrumentation*, 2022, 9(4): 49-57.
- [27] MOHAJERANI S, SAEEDI P. Cloud-Net: An end-to-end cloud detection algorithm for Landsat 8 imagery[C]. 2019 IEEE International Geoscience and Remote Sensing Symposium, 2019: 1029-1032.
- [28] RAPUANO E, MEONI G, PACINI T, et al. An FPGA-based hardware accelerator for CNNs inference on board satellites: Benchmarking with myriad 2-based solution for the CloudScout case study[J]. *Remote Sensing*, 2021, 13(8): 1518.
- [29] HE Q B, SUN X, YAN ZH Y, et al. DABNet: Deformable contextual and boundary-weighted network for cloud detection in remote sensing images[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2021, 60: 1-6.
- [30] HOWARD A, SANDLER M, CHU G, et al. Searching for mobilenet3[C]. 2019 IEEE/CVF International Conference on Computer Vision, 2019: 1314-1324.

作者简介



于希明, 2016 年于哈尔滨工业大学获得学士学位, 现为哈尔滨工业大学博士生, 主要研究方向为遥感图像处理与深度学习模型计算加速等。

E-mail: yuximing@hit.edu.cn

Yu Ximing received his B. Sc. degree from Harbin Institute of Technology in 2016. He is currently a Ph. D. candidate at Harbin Institute of Technology. His main research interests include remote sensing image processing and computing acceleration for deep learning model, etc.



彭宇, 2004 年于哈尔滨工业大学获得博士学位, 现为哈尔滨工业大学电子与信息工程学院教授, 主要研究方向为工业大数据智能解读、智能计算、计算加速及嵌入式人工智能等。

E-mail: pengyu@hit.edu.cn

Peng Yu received his Ph. D. degree from Harbin Institute of Technology in 2004. He is currently a professor in School of Electronics and Information Engineering at Harbin Institute of Technology. His main research interests include intelligent interpretation for industrial big data, intelligent computing, computing acceleration and embedded AI, etc.



刘连胜 (通信作者), 2006 年、2008 年和 2017 年于哈尔滨工业大学分别获得学士、硕士和博士学位, 现为哈尔滨工业大学教授, 主要研究方向为电子测量、基于 FPGA 的高能效计算技术等。

E-mail: lianshengliu@hit.edu.cn

Liu Liansheng (Corresponding author) received his B. Sc. , M. Sc. , and Ph. D. degrees all from Harbin Institute of Technology in 2006, 2008, and 2017, respectively. He is currently a professor and Ph. D. advisor at Harbin Institute of Technology. His main research interests include electronic measurement, FPGA-based energy-efficient computing technology, etc.