

展示用于地球科学应用的光谱分析算法和深度学习的在轨推理

Itai Zilberstein^{*1}, Alberto Candela¹, Steve Chien¹, David Rijlaarsdam², Tom Hendrix², Léonie Buckley², and Aubrey Dunne²

¹Jet Propulsion Laboratory, California Institute of Technology, United States

²Ubotica Technologies, Ireland

摘要

与 Ubotica Technologies 合作，喷气推进实验室正在 CogniSAT-6/HAMMER (CS-6) 上展示最先进的数据分析。CS-6 是一颗携带可见光和近红外范围高光谱仪器以及神经网络加速硬件的卫星。在边缘（例如机载）执行数据分析可以启用新的地球科学测量和响应。我们将使用深度学习和光谱分析算法，在 CS-6 上展示针对多种应用的数据分析和推理。




图 1: 火山监测快速响应工作流程概述。图像来源: Ubotica Technologies (步骤 1 和 2), Planet Labs (步骤 3)。

1 介绍

近年来，在轨资产进行地球科学研究的能力有了巨大飞跃。新的太空供应商正在部署配备最新多光谱和高光谱仪器以及提升机载计算能力的处理器的卫星。CogniSAT-6/HAMMER (CS-6) 是一款拥有可见光和近红外范围高光谱仪器及 AI 加速硬件的航天器，能够进行高级边缘数据分析 [1]。CS-6 是一款于 2024 年 3 月发射的 6U 立方体卫星。它位于高度约为 500 公里的太阳同步轨道上。在 CS-6 上搭载了一台 Myriad X 视觉处理单元 (VPU)，能够执行快速计算机视觉、图像信号处理和神经网络执行。CS-6 使用 HyperScape 100 仪器，能够在 440nm–884nm 范围内进行高光谱测量，并达到每像素地表距离为 5 米。

机载数据分析具有几个关键功能，包括快速响应检测到的现象以及通过识别不可用数据来减少数据量。前者依赖于推断数据采集的科学属性以指导未来测量的智能规划。在边缘（例如，在机上）执行此计算对于启用新的、时间敏感的罕见地球现象测量至关重要，否则如果需要地面分析则无法获得这些测量结果。航天器可以自我提示并利用第一次采集的知识来指导第二次在同一飞行过程中进行另

一次测量。这一概念称为动态定位，将实现更高分辨率的精确测量 [2], [3]。或者，一个航天器可以通过交叉提示另一个航天器以快速获得关键目标的后续图像。机载数据分析实现了美国宇航局新观测策略 (NOS) 计划的关键组成部分，该计划旨在推进观测系统。图 1 展示了一个用于机载数据推断的快速响应用例。热活动的检测会触发与地面站或其他资产的通信以进行快速后续行动。星间链路 (ISL) 使诸如 CS-6 之类的卫星能够交叉提示其他感知资产或参与去中心化调度 [4]。

在这项工作中，我们专注于开发和部署机载算法，包括光谱分析算法和深度神经网络（如卷积神经网络 (CNNs)），以在可见光和近红外光谱范围内进行图像分析和光谱特征检测的推理。利用 AI 加速硬件进行光谱分析是新颖的，并为边缘计算开辟了新的途径。我们针对众多地球科学应用，从云、野火、火山活动和有害藻华的检测到地表水、植被和矿物测绘及土地使用分类。本文详细介绍了将在 CS-6 和其他航天器上展示的推理算法的开发过程。这项正在进行的工作包括使用自动化标记技术为每个应用组成数据集，设计并在飞行硬件限制内实现算法，训练机器学习模型，验证推理和执行，并进行飞行演示。

^{*}itai.m.zilberstein@jpl.nasa.gov. ©2024. All rights reserved.

2 方法

2.1 数据集

CS-6 数据由于其最近发布 (2024 年 3 月) 而有限。对于光谱分析, 我们利用美国地质调查局光谱库 [5] 中的数据。图像数据集由 Open Cosmos 运营的 Menut 卫星的 190 个场景和来自 Planetscope 数据的数百个场景组成。我们使用这些数据产品的红、蓝、绿以及近红外波段。将 CS-6 波段进行拉伸以增强数据并使其与基于其他卫星场景训练的模型兼容。设 q_1 和 q_{99} 为一个波段的 1 分位数和 99 分位数。我们将每个像素 p 在一个波段中拉伸, 使其在范围 $[v_{min}, v_{max}]$ 内, 使用公式

$$\min \left[\max \left(v_{min} + \frac{v_{max} - v_{min}}{(q_{99} - q_1)} \cdot (p - q_1), v_{min} \right), v_{max} \right]. \quad (1)$$

我们从优化雾霾转换 (HOT) 方法为云层 [6]、归一化差异水指数 (NDWI) 方法为地表水域范围 (SWE) [7]、热活动的波段阈值 [8]、欧洲航天局的世界覆盖地图用于土地利用 [9], 以及 Sentinel-2 图像用于藻类水华中推导出自动化标记技术。诸如 HOT 和 NDWI 等方法可以直接从 VNIR 数据中计算得出。我们使用公式

$$NDWI = \frac{Green - NIR}{Green + NIR}. \quad (2)$$

计算 NDWI 掩码。

NDWI 产品随后使用 Otsu 的方法进行阈值处理, 以获得场景的二进制地表水掩模。HOT 方法利用非云像素的蓝色和红色波段值之间的关系。红色波段受大气雾霾的影响较小, 而蓝色波段散射较多。晴空线定义了这种相关性, 并且靠近这条线的数据点表示清晰像素, 远离这条线的数据点表示云或雾霾干扰。请注意, Planetscope 场景提供云掩模, 因此我们将 HOT 方法应用于 Menut 和 CS-6 数据产品进行标注。我们通过选择具有最小蓝色波段值的 0.15% 数据点来计算晴空线。这些点被分成 20 个区间, 对于每个区间选择红色波段值最高的 20 个点。给定这 400 个点, 我们使用线性回归拟合一条线。令 m 和 b 定义晴空线。我们计算 HOT 值为

$$HOT = |m \cdot Blue - Red| + \frac{b}{\sqrt{1 + m^2}}. \quad (3)$$

如同 NDWI, HOT 产品使用 Otsu 方法进行阈值处理以获得二进制云掩模。尽管使用了自动化技术, 标记的数据仍需人工验证以确保质量。

由于 CS-6 仅包含可见光和近红外数据产品, 因此对于某些应用而言, 科学回报受到限制。缺乏更

高波长的情况下, 云分类会受到雪、海岸线和其他高反射率物体的干扰。SWE 受到阴影和城市区域的影响。在没有 VSWIR 或 TIR 传感器的情况下, 热检测存在明显限制。尽管有这些缺点, 模型在评估中表现出高度准确性。

2.2 谱分析算法

光谱分析用于两种不同的应用: 矿物和植被制图。我们设计这些算法以利用 CS-6 上的 AI 加速硬件, 这是一种部署光谱算法的新方法。

我们使用三种常见方法: 光谱角度映射器 (SAM)、匹配滤波器 (MF) 和里德-夏利异常检测器 (RX)。

SAM 是一个衡量任意两个光谱相似性的函数: x 和 y 。它推广了 N 维空间中两个向量之间角度的概念。小的 SAM 值表示高度相似, 反之亦然。它是按照以下方式计算的:

$$SAM(x, y) = \cos^{-1} \left(\frac{x \cdot y}{\|x\| \|y\|} \right). \quad (4)$$

MF 还量化了两个光谱之间的相似性, 但它通过使用场景统计信息 μ (均值) 和 Σ (协方差) 来缩放和归一化响应。较大的 MF 值表明光谱 x 与感兴趣的目标 t (例如, 一种已知矿物的光谱) 之间有更强的匹配度。MF 是一个由公式给出的线性检测器:

$$MF(x, t; \mu, \Sigma) = \frac{(t - \mu)^T \Sigma^{-1} (x - \mu)}{(t - \mu)^T \Sigma^{-1} (t - \mu)}. \quad (5)$$

RX 还使用场景统计信息 μ 和 Σ 。然而, 它并不测量两个光谱之间的相似性, 而是衡量一个光谱 x 相对于场景的异常程度。较大的值表示离群点。其计算方法类似于 MF:

$$RX(x; \mu, \Sigma) = (x - \mu)^T \Sigma^{-1} (x - \mu). \quad (6)$$

最后, 正在进行和未来的工作包括使用深度学习进行光谱解混 [10]。

2.3 卷积神经网络

图像分析包括使用专门为飞行硬件部署定制的 [11] 深度卷积神经网络架构进行语义分割。我们需要能够提供高质量、快速分类并使用最少计算资源的模型。为了最小化 CPU 计算, 我们将预处理操作 (如归一化) 嵌入为 CNN 中的层。

训练好的模型识别云层、地表水范围 (洪水)、热事件 (例如, 火山、野火)、地表类型 (例如, 城市、森林、水域、农田等) 以及有害藻华。




图 2: 卷积神经网络将用于许多科学事件的机载分析。

用于分割应用的模型, 如云筛选和地表水范围, 是通过优化稀疏分类交叉熵损失来训练的。对于热检测, 正面分类要少得多, 因此我们优化稀疏分类交叉熵损失的加权版本。权重基于训练集中的类别分布设定。

2.4 评估与验证

我们在地面硬件上评估算法的质量, 并在飞行前验证其在飞行硬件上的计算。表 1 显示了三个二值图像分类器在测试数据集上的准确率和交并比 (IoU)。云层和热检测的准确率均超过 97%, 并且负类 (标签 0) 的 IoU 高于正类 (标签 1) 的 IoU。地表水范围的性能低于其他分类器, 但仍保持 87% 的准确率。在许多应用中, 模型过分类比出现假阴性更可取。

除了评估模型质量, 我们还在 CPU 和 Myriad X 硬件上验证了模型大小、运行时间和错误。表 2 显示了在 Myriad X VPU 上运行时的模型大小和单个输入执行时间。光谱算法的输入维度更高, 尽管与 U-Nets 相比模型尺寸更小, 但导致运行时间较长。图 3 说明了当在 Myriad X 与传统 CPU 上运行时用于植被检测的光谱算法的错误。正如分析所确认的, 除了由于浮点算术造成的微小偏移外, 我们期望看到几乎相同的输出。

Application	Clouds	SWE	Thermal
Accuracy	0.9748	0.8730	0.9988
Positive IoU	0.9063	0.7069	0.9715
Negative IoU	0.9144	0.8101	0.9988

表 1: 当前最佳性能的 U-Net 模型在测试集数据上三种应用的结果。表中的模型执行二元分类, 因此正面指的是标签 1, 负面指的是标签 0。

Application	Model	Model Size	Execution Time (s)
Clouds	U-Net Xception	4.5 MB	0.4781
	U-Net UAVSAR	4.3 MB	0.5293
SWE	U-Net Xception	4.5 MB	0.4938
	U-Net UAVSAR	4.3 MB	0.5333
Thermal	U-Net Xception	4.5 MB	0.4800
	U-Net UAVSAR	4.3 MB	0.5307
Vegetation	SAM	175 KB	2.499
	MF	177 KB	4.3060
	RX	3 KB	3.119
Mineral	SAM	4 KB	10.0871
	MF	6 KB	17.9930
	RX	3 KB	13.5023

表 2: 模型大小及在 Myriad X VPU 编译和执行时的单次输入执行时间。




图 3: CPU 和 Myriad X VPU 上光谱分析算法计算的验证。

3 当前状态

开发始于深度学习模型的训练和光谱算法的工程化。然后在 Myriad X Neural Compute Stick 上测试这些模型。最后，在 Ubotica 的 flatsat 测试平台上执行模型，然后再上传并在 CS-6 上使用。

我们为之前列出的应用开发了几十个模型。其中一组初始的小型模型已在平版卫星测试床上进行了验证，并将于 2024 年 9 月在 CS-6 上进行飞行试验。这些模型包括用于云筛选、地表水范围和热活动检测的 CNNs。图 4 显示了由 CS-6 拍摄的两个场景中的云分类和地表水范围，如机载计算所示。演示将包括收集一个场景、该收集的机载数据推理以及接收包含数据摘要的 ISL 消息。完整的数据和分割将在实验后通过下行链路接收到以进行进一步分析。

光谱分析算法将在 2024 年秋季 CNNs 之后在 CS-6 上进行演示。在地面硬件上，这些算法已通过 CS-6 图像验证了矿物和植被检测应用，如图 5 和 6 所示。

4 结论

利用边缘计算进行机载数据分析是地球观测资产的一项令人兴奋的新能力，为新的地球科学开辟了道路。光谱分析可以揭示高维数据的深层特征。图像分析可以在场景中快速检测感兴趣的目标特征。将这些过程工程化以在边缘执行需要保持高性能的轻量高效模型。我们希望提升这一能力的技术成熟度，使其能够部署到未来的地球科学任务中。除了在 CS-6 上展示更多应用和模型外，我们还计划将这些模型部署到更多的航天器上。此外，我们还计划在未来飞行演示 [12], [13] 中将机载推理与诸如动态定位和多资产联合调度等其他技术进行整合。

5 致谢

本工作的部分内容由加州理工学院的喷气推进实验室在与美国国家航空航天局 (80NM0018D0004) 签订的合同下完成。本工作得到了 NASA 地球科学和技术办公室 (ESTO) 的支持。感谢政府资助。

REFERENCES

- [1] D. Rijlaarsdam et al., “The next era for Earth observation spacecraft: An overview of CogniSAT-6,” TechRxiv, Feb. 2024.
- [2] A. Candela, J. D. Victoria, I. Zilberstein, M. Kurowski, Q. Yue, and S. Chien, “Dynamic targeting scenario to study the planetary boundary layer,” in International Geoscience and Remote Sensing Symposium, IEEE, Jul. 2024.
- [3] A. Candela, J. Swope, and S. Chien, “Dynamic targeting to improve Earth science missions,” Journal of Aerospace Information Systems, vol. 20, no. 11, pp. 679–689, 2023.
- [4] I. Zilberstein, A. Rao, M. Salis, and S. Chien, “Decentralized, decomposition-based observation scheduling for a large-scale satellite constellation,” in International Conference on Automated Planning and Scheduling, vol. 34, 2024, pp. 716–724.
- [5] R. Kokaly et al., “USGS Spectral Library Version 7: U.S. Geological Survey Data Series 1035,” p. 61, doi: doi.org/10.3133/ds1035.
- [6] X. Zhu and E. H. Helmer, “An automatic method for screening clouds and cloud shadows in optical satellite image time series in cloudy regions,” Remote sensing of environment, vol. 214, pp. 135–153, 2018.
- [7] S. Cooley, L. Smith, L. Stepan, and J. Mascaro, “Tracking dynamic northern surface water changes with high-frequency planet cubesat imagery,” Remote Sensing, vol. 9, no. 12, p. 1306, 2017.
- [8] J. Mason et al., “Fully automated volcano monitoring and tasking with planet skysat constellation: Results from a year of operations,” in International Geoscience and Remote Sensing Symposium, IEEE, 2023, pp. 829–832.
- [9] European Space Agency, Worldwide land cover mapping, <https://esa-worldcover.org/en>, Online; accessed 24 May, 2024.




图 4: 两个由 CS-6 拍摄的场景 (左), 以及在机上通过深度学习模型获得的云筛选 (右上) 和地表水范围 (右下) 的相应推断。包含来自 CogniSAT-6/HAMMER, 2024, Open Cosmos Limited 的图像。版权所有。




图 5: 使用三种光谱分析算法对 CS-6 场景 (左) 进行植被检测。包含来自 CogniSAT-6/HAMMER, 2024, Open Cosmos Limited 的图像。所有权利保留。




图 6: 植被光谱比较: CS-6 图像 (蓝色) 与美国地质调查局光谱库中的一个示例 (橙色)。

- [10] A. Candela Garza, “Bayesian models for science-driven robotic exploration,” Ph.D. dissertation, Carnegie Mellon University, Pittsburgh, PA, Sep. 2021.
- [11] O. Ronneberger, P. Fischer, and T. Brox, “U-net: Convolutional networks for biomedical image segmentation,” in International Conference on Medical Image Computing and

Computer-Assisted Intervention, Springer, 2015, pp. 234–241.

- [12] S. Chien, A. Candela, I. Zilberstein, D. Rijlaarsdam, T. Hendrix, and A. Dunne, “Leveraging commercial assets, edge computing, and near real-time communications for an enhanced New Observing Strategies (NOS) flight demonstration,” in International Geoscience and Remote Sensing Symposium, IEEE, Jul. 2024.
- [13] S. Chien et al., “Flight of dynamic targeting on the CogniSAT-6 spacecraft,” in International Symposium on Artificial Intelligence, Robotics and Automation in Space, Nov. 2024.