arXiv:2305.04059v1 [cs.LG] 6 May 2023

用于低地球轨道场景分类的去中心化半监督星载学习

Johan Östman[1], **Pablo Gómez**[1,3], **Vinutha Magal Shreenath** [1], **Gabriele Meoni**[1,2]

[1] AI Sweden，Lindholmspiren 11，417 56 哥德堡，瑞典

[2] Φ-实验室，欧洲空间局，ESRIN，弗拉斯卡蒂，意大利

[3] 先进概念团队，欧洲空间局，ESTEC，诺德韦克，荷兰 pablo.gomez@esa.int

最新卫星硬件上的星载机器学习有望显著降低通信和运行成本。我们展示了如何基于神经网络的卫星处理器基准测试，在卫星星座上使用半监督学习训练用于场景分类的机器学习模型，同时考虑温度和有限功率预算等运行约束。我们评估了采用去中心化和联邦学习方法的任务场景。所有场景均能在一天的任务时间内收敛至较高准确率（在 EuroSAT RGB 数据集上约为 91%）。

1 引言

新一代卫星正将适用于航天器上的机器学习（ML）的硬件送入地球轨道。近期研究 [1] 探讨了在卫星星座上以分布式方式训练 ML 模型的可行性。通过共享在传感器附近训练的 ML 模型，而非收集到的数据，星上分布式训练有望降低通信需求、运行成本和耗时，并提升自主性。以往任务已展示了航天器上执行推理以进行数据处理的能力 [2], ，但星上训练带来了额外挑战。妥善应对运行约束至关重要，因为训练的计算成本显著更高，而且任务期间缺乏带标签样本往往会成为难以克服的障碍。

在这项工作中，我们研究了如何在卫星星座上训练用于场景分类的机器学习模型。我们采用了一种名为 MSMatch 的半监督学习方法 [3],

我们成功地利用去中心化学习技术对其进行了分布式训练。我们使用 PASEOS [4]，（一种专用的 Python 模块）对温度、通信窗口和有限功率预算等运行限制进行了建模。我们详细展示了涉及去中心化学习和联邦学习方法的多种场景的结果。

2 方法

本研究由三个核心部分构成：半监督学习方法 MSMatch、使用 PASEOS 对约束进行建模，以及调整 MSMatch 以实现分布式实现。

2.1 MSMatch

航天器上机器学习应用面临的主要挑战之一是带标签训练数据稀缺，尤其是在发射前。通常，在地面训练模型时，带标签样本数量不足，因此许多情况下必须使用半监督和自监督技术。MSMatch 是一种专为此类场景设计的半监督分类方法 [3], ，事实证明，即使每个类别仅使用少量标签进行训练，也能达到很高的准确率。

MSMatch 使用一致性正则化和伪标签，主要基于无标签图像进行训练。其核心是确保模型对同一图像经过两种不同增强（分别为强增强和弱增强）后的版本作出一致的预测。系统会为弱增强版本生成伪标签。此外，还会对数量有限的带标签样本应用监督损失。每个类别仅需五个带标签样本，MSMatch 在 EuroSAT [5] 等成熟基准测试上的准确率就能超过 90%。该方法也已证明适用于多光谱数据。

在我们的实现中，我们以在线提供的现有开源代码库[1]为基础进行了开发。我们采用了源自原始 EfficientNet [6], 的 EfficientNet-lite 模型（efficientnet-lite0）作为后端。由于这些模型的内存占用较小且运行效率较高，因此非常适合用于嵌入式系统，进而也适用于星载处理器。

2.2 PASEOS

在太空中训练机器学习模型，需要考虑功率预算、热管理和通信窗口等因素，因为这些因素会直接影响训练的可行性 [4]。尤其是在分布式计算场景中，通信窗口是一个关键因素 [1], [7]。

为对这些约束进行建模，我们采用开源 Python 模块 PASEOS [4] （版本 0.1.3）。PASEOS 对航天器的轨道动力学和功率预算进行仿真，同时考虑功耗、可用的太阳能电池板以及日食。热管理采用单节点常微分方程进行建模 [4]。分组通信根据假定的可用带宽以及通信伙伴之间是否存在视距进行计算。PASEOS 异步于训练流水线运行，从而限制了

[1]https://github.com/gomezzz/MSMatch 访问日期：2023-02-27

训练和交换模型的能力。有关这些模型的全面描述，请参阅专门介绍 PASEOS [4] 的文章。

2.3 去中心化 MSMatch

在本研究中，我们通过利用合并本地模型的成熟技术（例如联邦平均 [1]），展示了在分布式环境中训练 MSMatch 的能力。我们采用消息传递接口（MPI），在为每颗卫星并行运行 PASEOS 仿真的同时，实现多个模型的异步训练。假设在发射前即可获得带标签训练数据，并将其预加载到每颗卫星上。另一方面，无标签训练数据会随机分配到各颗卫星，每颗卫星接收固定数量的不同无标签样本。去中心化 MSMatch 的超参数与 [3], 中的设置基本相当，但有几处例外：带标签数据的批量大小减少为 32，无标签数据的批量大小减少为 96，学习率则提高到 0.03。当 PASEOS 仿真表明存在可进行数据交换的窗口时，MPI 便会促进通信。图 1 展示了一个涉及两颗卫星和一个地面站的去中心化 MSMatch 场景。需要注意的是，虽然各卫星共享相同的带标签样本，但无标签数据各不相同。我们工作的代码已在网上公开[2]。

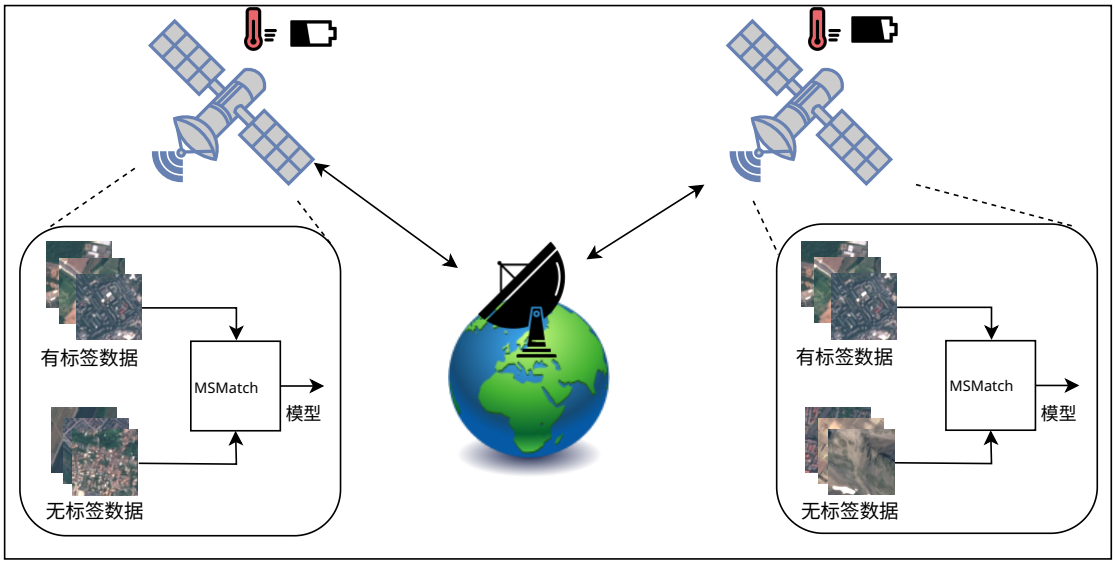


图 1：适用于两颗卫星和一个地面站的去中心化 MSMatch。

[2]https://github.com/gomezzz/DistMSMatch 访问日期：2023-04-05

3 结果

3.1 设置与场景

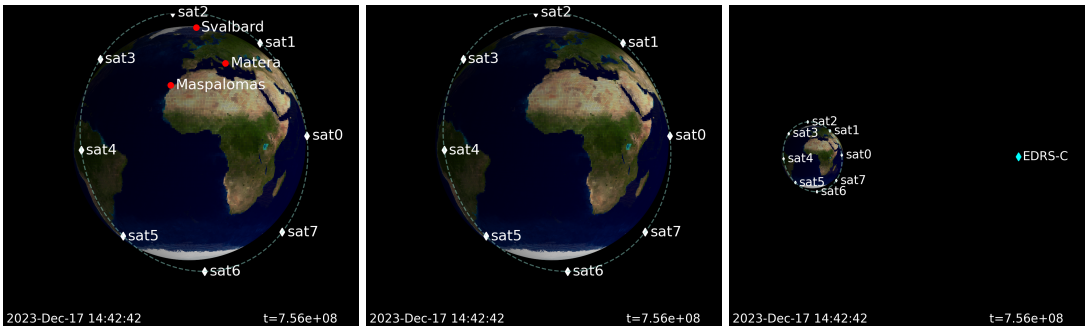
为测试所提出的方法，我们采用原始 MSMatch 论文 [3] 中使用的 EuroSAT 数据集 [5]，以便进行直接比较。该数据集由 Sentinel-2A 数据中的 27000 64×64 像素、13 通道图像组成，并分为十个类别，例如森林或河流。在实验结果中，我们仅使用 RGB 通道。之所以只采用 RGB 通道，主要基于两个因素：首先，RGB 通道已经展现出令人满意的性能；其次，纳入所有通道将大幅延长训练时间。不过需要注意的是，仅依赖 RGB 通道使我们处于较为不利的情形，而利用更多可用数据很可能会进一步提升性能。

为展示半监督学习能力，我们从每个类别中抽取五张有标签图像，共计 50 张有标签图像，并将其加载到每颗卫星上。也就是说，每颗卫星加载的都是相同的 50 张图像。测试集包含 2700 张图像，其余 24250 张图像作为无标签数据，并随机划分为八个分区，即每个分区平均包含 3031.25 张图像。

卫星与地面站通信时使用 1 Mbps 的射频（RF）链路，在轨通信时则使用速率为 100 Mbps 的光学星间链路（ISL）。考虑到跟踪和对准，我们假设每次尝试通信前，两颗卫星之间的 ISL 建立时间为 30 秒 [8]。卫星配备了容量为 0.2772 MJ 的电池，以及充电功率为 20 W 的太阳能电池板。热模型参数假设卫星质量为六千克，初始温度为 26.85 摄氏度，太阳吸收率为 0.9，红外吸收率为 0.5。每颗卫星朝向太阳和地球的表面积分别为 0.015 m^2和 0.01 m^2, 。辐射面积为 0.1 m^2 ，热容量为 5000 J/(kg * K)。所用的 EfficientNet-lite0 网络在压缩状态下占用 12.7 MB 存储空间，与地面站交换模型需要 201.78 秒，而通过 ISL 交换模型需要 32.03 秒。Unibap iX10 卫星处理器的 CPU 训练一个批次需要 15.98 秒。此外，假设与地面站通信、通过 ISL 通信、训练和待机的功耗分别为 10 W、13.5 W、30 W 和 5 W。PASEOS 仿真采用 v0.1.3 的默认配置运行。仿真的初始时刻为 2022-Dec-17 14:42:42。

如图 2 所示，所研究的分布式场景涉及一个由八颗卫星组成、运行于类 Sentinel 轨道（高度为 786 km、倾角为 98.62°、太阳同步轨道）的星座。第一个场景（地面站）假设通过位于大加那利岛、斯瓦尔巴群岛和意大利马泰拉的三个（相互连接的）地面站进行模型交换。从卫星的视角来看，这些地面站被视为一个整体。在第二个场景（SWARM）中，假设八颗卫星通过星间链路（ISL）进行通信。最后，在第三个场景（中继）中，假设欧洲数据中继卫星系统（EDRS-C）的一颗中继卫星充当联邦学习的中央服务器。忽略了中继卫星可能因繁忙而产生的通信延迟。在联邦设置（地面站和中继）中，每当本地模型可用时，全局模型便会通过全局模型与新接收模型的凸组合进行异步更新，二者的权重为 0.4，更新方式类似于 [9]（采用恒定加权函数）。此外，每个

卫星将尝试每隔 1000 秒共享一次本地模型。



(a) 地面站。 (b) SWARM。 (c) 中继。

图 2：不同星座和通信配置的可视化。

3.2 训练结果

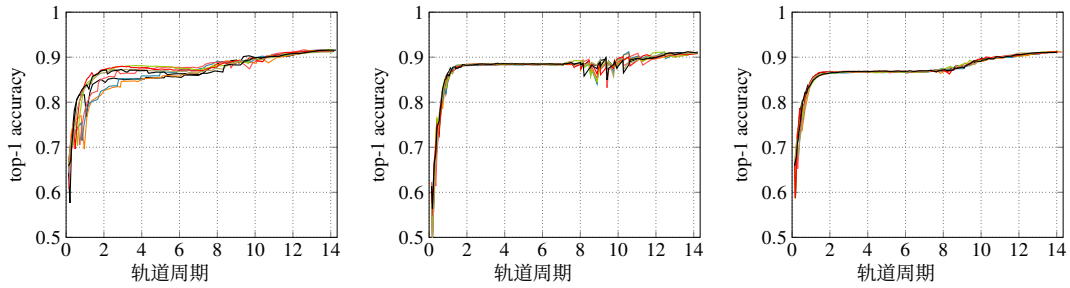
对 24 小时仿真时间（相当于 14.34 个轨道周期）内获得的结果，针对每种场景分别进行了三次独立运行，并对结果取平均值，如表 1 所示。三种场景的平均准确率均超过 91%，其中地面站场景的准确率最高，达到 91.51%。此外，可以看出，中继场景的标准差最低，而 SWARM 场景的标准差最高。这是预期之中的，因为与 SWARM 场景不同，中继和地面站场景均涉及全局模型的共享。

SWARM 场景的通信需求最高，卫星平均共享 1168.40 MB 的数据。这是因为始终有邻近卫星可用于接收本地模型。相比之下，RELAY 场景中的卫星平均传输了 455.61 MB 的数据，远低于 SWARM 场景。这一差异是因为中继卫星偶尔会被地球遮挡。GROUND STATION 场景的数据传输量最少，卫星仅传输了 185.74 MB 的数据，因为与地面站的链路并非经常可用。

在模拟的 24 小时期间，GROUND STATION、SWARM 和 RELAY 场景中的卫星

表 1：八颗卫星在三次不同运行中的平均结果。

配置	准确率 [%]	传输量数据 [MB]	功率消耗 [Wh]	训练时间 [% 的总量]	通信时间 [% 的总量]	时间间隔通信 [s]
地面站点	91.51 ±0.95	185.74	447.58	54.25	1.71	5913.6
SWARM	90.96±1.34	1168.40	449.36	53.76	3.34	1878.4
中继	91.19±0.76	455.61	449.37	54.45	1.32	2349.3



(a) 地面站。 (b) SWARM。 (c) 中继。

图3：三次运行的卫星测试集 Top-1 准确率平均值。不同颜色表示不同的卫星。

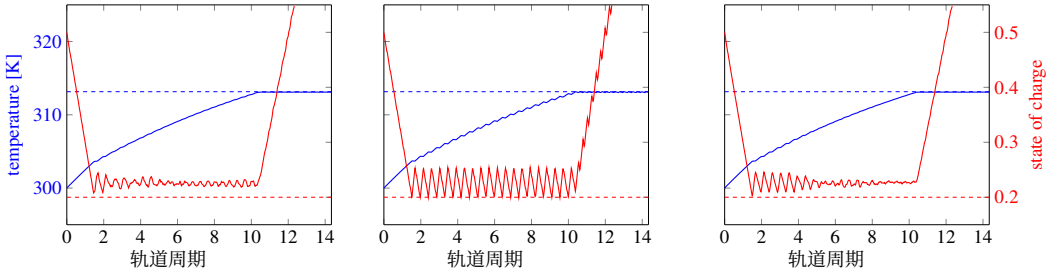
分别平均传输其本地模型 14.625 次、46 次和 35.875 次。不过，需要注意的是，这并未反映在通信所占时间的相对长短上：由于 GROUND STATION 依赖射频通信，RELAY 场景的通信时间最短。三种场景的功耗和总训练时间相近。但请注意，运行地面站或中继卫星的成本未计入其中。

图3展示了各颗卫星 Top-1 准确率（取三次独立运行的平均值）的收敛情况。在 SWARM 和中继场景中，由于通信频繁，卫星之间的性能表现更加一致，从而避免了卫星之间出现显著偏差。SWARM 场景约在两个轨道周期后达到局部最优，Top-1 准确率为 88.5%；而中继场景在相同时间内达到的局部最优较差，Top-1 准确率为 86.7%。有趣的是，这两个场景中的卫星在八个轨道周期后均摆脱了局部最优，并在运行 12 个轨道周期后找到了更优的最优点。尽管地面站场景的表现不如另外两个场景一致，但也呈现出类似的行为。

如前所述，PASEOS 支持将功率和温度等约束纳入考量。图4展示了平均温度和功耗。在我们的数值实验中，当荷电状态低于 0.2 或温度超过 313.15 K 时（图4中的虚线所示），航天器会进入待机模式以充电或冷却。不过，通信具有优先级，始终会执行。

在所有设置下，温度的变化都类似，因为主要影响因素是训练过程。从蓝色曲线可以观察到，约经过 10 个轨道周期后，温度会触发待机模式。随后，卫星进入待机模式以冷却，并在温度不再违反约束时立即开始训练，从而使温度围绕约束温度波动。

相比之下，荷电状态（以红色曲线表示）在这三种场景中呈现出不同的变化。在 SWARM 场景中，航天器始终会交换各自的模型。然而，在地面站和中继场景中，卫星并非总能建立通信链路来共享本地模型，因此卫星的电池消耗较难预测。由于训练的功率消耗最高，而且轨道使航天器能够



(a) 地面站。 (b) SWARM。 (c) 中继。

图 4：星座的平均温度和荷电状态。温度以蓝色表示，荷电状态以红色表示。

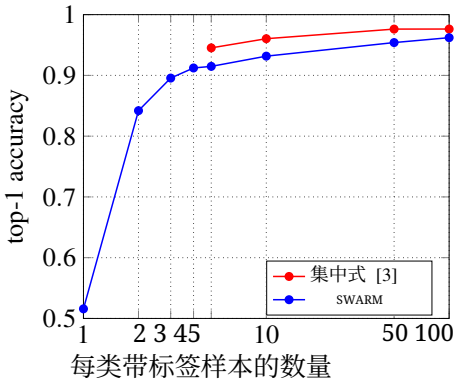


图5：SWARM 的 Top-1 测试准确率与每类带标签样本数量的关系。各点为所有卫星及三次独立运行结果的平均值。

在大部分时间内充电，温度触发的待机模式越频繁，航天器就越能为电池充电。

图3所示的结果基于每类5个带标签样本，其余数据样本均未标记。为评估有标签数据集大小的影响，我们聚焦于 SWARM 场景，并通过改变有标签数据集大小开展实验。图5展示了平均 Top-1 准确率（所有卫星及3次独立运行的平均值）。

正如预期，随着有标签数据集规模的扩大，Top-1 准确率也会提高。值得注意的是，每类仅有 3 个带标签样本时，性能便接近 90%；每类有 100 个带标签样本时，Top-1 准确率达到 96.2%。为便于比较，我们纳入了 MSMatch 集中式实现的性能 [3]。需要指出的是，这种比较可能并不完全公平，因为集中式版本的训练时间要长得多，而且采用了规模更大的 EfficientNet 模型。尽管如此，本文提出的 MSMatch 分布式版本表现出了竞争力，并取得了相当的性能。

4 结论

本研究展示了利用当前卫星处理器，在卫星星座上以半监督方式分布式训练先进神经网络的可行性。根据轨道配置和可用资源，星座在模拟训练 24 小时后，能够以最高 91.51% 的准确率对 EuroSAT 数据集进行分类。展望未来，纳入更复杂的场景、通信方案并改进卫星架构，将有助于进一步优化并提升逼真度。

5 致谢

作者感谢 Unibap AB 提供用于实验的 iX-10 100 设备。Johan Östman 的研究工作由 Vinnova 通过项目资助 2020-04825 提供经费；Vinutha Magal Shreenath 的研究工作由 Vinnova 通过项目资助 2021-03643 以及瑞典国家航天局通过项目资助 2022-00013 提供经费。

参考文献

[1] B. Matthiesen、N. Razmi、I. Leyva-Mayorga、A. Dekorsy 和 P. Popovski，《卫星星座中的联邦学习》，*arXiv* 预印本 *arXiv:2206.00307*，2022 年。[2] G. Giuffrida、L. Fanucci、G. Meoni、M. Batič、L. Buckley、A. Dunne、C. van Dijk、M. Esposito、J. Hefele、N. Vercruyssen、G. Furano、M. Pastena 和 J. Aschbacher，《The Φ-sat-1 任务：首个用于卫星地球观测的星载深度神经网络演示系统》，*IEEE* 地球科学与遥感汇刊，第 60 卷，第 1–14 页，2022 年。[3] P. Gómez 和 G. Meoni，《MSMatch：少量标签条件下的半监督多光谱场景分类》，*IEEE* 应用地球观测与遥感精选主题期刊，第 14 卷，第 11 643–11654 页，2021 年。[4] P. Gómez、J. Östman、V. M. Shreenath 和 G. Meoni，《PASEOS：用于模拟多航天器运行环境》，*arXiv:2302.02659 [cs.DC]*, 2023。[5] P. Helber、B. Bischke、A. Dengel 和 D. Borth，《EuroSAT 简介：用于土地利用与土地覆盖分类的新型数据集和深度学习基准》，发表于*IEEE* 国际地球科学与遥感研讨会（*IGARSS*），2018 年，第 204–207 页。[6] M. Tan 和 Q. Le，《EfficientNet：重新思考卷积神经网络的模型缩放》，发表于国际机器学习会议，PMLR，2019 年，第 6105–6114 页。[7] N. Razmi、B. Matthiesen、A. Dekorsy 和 P. Popovski，《面向密集低地球轨道星座的星上联邦学习》，发表于*ICC 2022—IEEE* 国际通信会议，IEEE，2022 年，第 4715–4720 页。[8] D. Bhattacharjee、A. U. Chaudhry、H. Yanikomeroglu、P. Hu 和 G. Lamontagne，《激光星间链路建立延迟：量化、影响及可容忍值》，*arXiv:2301.0528[cs.NI]*, 2023。

[9] C. Xie、S. Koyejo 和 I. Gupta，《异步联邦优化》，*arXiv:1903.03934[cs.DC]*, 2019。