

轻量级卷积神经网络用于嵌入式 SAR 船舶目标检测与分类

Fabian Kresse^{1,3}, Georgios Pilikos^{1,4}, Mario Azcueta², Nicolas Floury¹

¹Wave Interaction & Propagation, RF Payloads & Tech. Div., Elec. Dept., ESA/ESTEC, NL-2200AG Noordwijk, The Netherlands

²Copernicus Sentinel-1 Payload, Copernicus Space Component, ESA/ESTEC, NL-2200AG Noordwijk, The Netherlands

³Institute of Science and Technology Austria (ISTA), AT-3400 Klosterneuburg, Austria

⁴Department of Neuroscience, Erasmus MC, NL-3000CA Rotterdam, The Netherlands

ABSTRACT

合成孔径雷达 (SAR) 数据能够实现对海上船只的大规模监视。然而, 近实时监控目前受到限制, 因为需要下行传输所有原始数据, 执行图像聚焦, 然后在地面进行分析。机载处理以生成更高级别的产品可以减少需要下行传输的数据量, 缓解带宽限制并最小化延迟。然而, 由于卫星的有限内存、处理能力和计算资源, 传统的图像聚焦和处理算法面临挑战。本文提出并评估了用于对通过 Sentinel-1 获取的 Stripmap 和干涉宽幅 (IW) 模式的未聚焦 SAR 数据进行实时推断的神经网络。我们的结果证明了在 FPGA 上进行机载处理和部署其中一个模型的可行性。此外, 通过研究船只和风车之间的二分类任务, 我们证明了目标分类是可能的。

Index Terms— Deep Learning, raw echo data, ship detection, synthetic aperture radar (SAR), Field-Programmable-Gate Array (FPGA)

1. 引言

合成孔径雷达 (SAR) 卫星数据使得全天候海事监控成为可能。传统的地面基于恒定虚警率 (CFAR) 在聚焦 SAR 图像上的 [2] 检测需要一个昂贵的数传、聚焦和分析流程, 导致延迟和有限的通信窗口。直接在卫星上处理数据通过生成更高抽象级别的输出 (例如, 检测到的船只的像素坐标) 而不是原始数据, 显著减少了需要下传的数据量。在该领域, 深度学习模型显示出良好的效果 [11, 12, 13, 4, 17], 提供了一个直接在嵌入式设备上进行推理优化的机会。然而, 在卫星上获得完全聚焦的 SAR 图像在计算和内存方面都是非常密集的, 这促使了关于使用中间原始 [3, 10] 或范围压缩数据产品进行机载船只检测的研究 [16, 9, 8]。总体而言, 一个有效的机载 SAR 船只检测算法必须处理小数据段以适应有限的机载内存, 保持适合现场可编程门阵列 (FPGAs) 的紧凑模型, 直接输出船只坐标以减少下传和存储需求, 并且仍然实现高精度。尽管先前的工作解决了该流程中的单个元素, 但在嵌入式 FPGA 限制下, 没有任何方法能在非聚焦或范围压缩数据上实现实时、准确的检测。

在这项工作中, 我们提出了一系列针对 Stripmap 和 Interferometric Wide (IW) SAR 数据设计的轻量级深度学习模型, 这些数据由 Sentinel-1 获取, 旨在满足机载数据处理的需求。我们的模型配置, 处理原始和范围压缩数据, 是建立在 ResNet 模块 [5] 之上的单阶段检测器, 允许灵活的模型尺寸设置。它们采用单阶段检测层作为最后一步, 依据 YOLO 框架 [14] 的网格方法执行坐标预测和目标分类。我们在 Stripmap 模式数据上运行的最小模型在我们的评估场景中提供了近乎完美的船舶检测结果。此外, 我们展示了该模型可以成功部署在 Xilinx Zynq UltraScale+ MPSoC ZCU104 FPGA 上, 实现足够的吞吐量以用于实时处理。对于 IW 数据, 我们评估了多种模型尺寸的性能, 在开阔水域场景中取得了有竞争力的结果, 并为未来的研究提供了宝贵的见解。我们还展示了我们的模型可以执行二进制目标分类, 在我们使用的 IW 数据集上区分风车和船只。

2. 提出的深度学习算法

图 1 展示了传统方法 (包括距离和方位压缩) 以及我们采用的方法的处理流程。类似于之前的工作 [3], 对于 Stripmap 模式, 我们直接处理原始数据, 而对于 IW 数据, 我们执行距离压缩。

条带图预处理: 我们在距离维度上将原始数据移动半个脉冲长度, 以便特征响应与单视复合 (SLC) 标签对齐, 从而考虑模式和脉冲特定的采集偏移。

IW 预处理: 经过范围压缩的 IW 特征和 SLC 标签是错位的, 因此我们在它们的像素空间之间应用局部一致的映射。我们计算每个范围压缩裁剪的中心像素的偏移量, 并使用它来移动相应的标签裁剪。

模型: 我们采用 YOLO 风格的架构, 因为它具有高效的单阶段设计, 可以在没有区域提案的额外开销下进行快速推理 [14]。骨干网络由四层 ResNet 块组成, 前面是一个有 64 个核的 7×7 卷积。与之前的工作一样, 我们将复数值 SAR 数据视为两个独立的输入通道 [3]。我们将网络应用于原始 SAR 图像的裁剪部分。网络在 YOLO 风格的网格上输出预测, 其中每个网格单元预测坐标 (x, y) 和表明目标存在的对象性分数。由于我们数据集中的船只占据的尺寸范围较窄, 我们省略了 YOLO 中典型的多尺度锚定检测。我们还针对 IW 数据在船只和风车之间进行二分类, 添加了两个额外的输出。我们

F. Kresse and G. Pilikos performed this work while at ESA and are no longer affiliated with the agency.
Correspondence: Nicolas.Floury@esa.int




Fig. 1. 传统的流水线（黑盒）在检测前聚焦数据。而我们的方法绕过了这一点：我们直接在原始 Stripmap 回波 [3] 和距离压缩的 IW 数据上进行检测。

的输出网格尺寸为 $S \times S$ ，每个单元对应输入数据中的一个 32×32 像素区域。例如，输入裁剪尺寸为 128×128 会导致输出网格尺寸为 4×4 。我们实验中评估的模型配置列于表格 1 中。

Table 1. 每个 Resnet 块包含两个卷积，这些卷积的核大小为 3×3 ，批归一化和 ReLU 激活。

Param. (Size)	Blocks per Layer	Channels
96800 (S)	1, 2, 2, 1	16, 16, 32, 32
1222368 (M)	3, 4, 6, 3	64, 64, 64, 64
11222880 (L)	2, 2, 2, 2	64, 128, 256, 512

损失函数：我们采用标准的 YOLO 损失，仅省略边界框大小回归项，而保留所有其他成分不变。

船舶位置预测：在获得预测结果后，我们为每个检测到的船舶分配一个固定的 50 像素边界框。与 YOLO 流程 [14] 类似，我们应用非最大抑制 (NMS) 来去除重叠的框，保留置信度最高的框。接受阈值设置为 Youden J 阈值 [15] 和来自验证数据的最小距离阈值的较小值，并四舍五入到两位小数。我们计算一个基于距离的 $F1$ 得分 $F1_{30}$ ，若一个预测在距离某个真实标签 30 像素以内则视为正确；未匹配的预测和标签分别为假阳性和假阴性。鉴于 SAR 分辨率 (Stripmap 为 $5 \text{ m} \times 5 \text{ m}$, IW 为 $5 \text{ m} \times 20 \text{ m}$)，这个容差在距离上等于 150 米，在方位上最多 600 米，以适应细微的定位误差，同时仍远低于固定的框尺寸。

3. 实验

我们使用两个不同的数据集评估我们提出的模型。第一个数据集由原始 SAR Sentinel-1 条带模式 (S6) VV 极化数据组成，之前曾被 [3] 使用过。我们展示了在此数据集上训练的模型可以部署在 FPGA 上，实现实时吞吐量。然后我们研究了来自上海港口的 IW 数据集。对于此数据集，我们展示了良好的离岸检测性能以及我们的模型区分风车和船舶的能力。我们的两个数据集最初均来自 Copernicus 数据空间生态系统 [1]。所有有标准差的实验均使用三个种子进行。

3.1. 哨兵-1 条带模式

来自 [3] 的数据集总共包含 12 张来自圣保罗港的 SAR 图像，其中一张用于验证 (84 艘船)，两张用于测试 (155 艘船)，其余用于训练 (726 艘船)。我们调查了在第 2 节中描述的最小模型的性能，该模型的裁剪尺寸为 128×128 ，在我们的第一和第二张测试图像上分别达到了 0.98 ± 0.00 和 0.97 ± 0.01 的得分 (定性结果见图 2)。在手动检查了少数错误预测后，这些错误可以归因于船只的双重检测，NMS 不够激进以及标签歧义。

3.2. 用于 Sentinel-1 条带模式的嵌入式推理

我们将经过 8 位 AdaQuant 量化的 [6] 模型 (通过 Vitis AI 3.0 [7]) 部署在 Zynq UltraScale+ MPSoC ZCU104 FPGA 上，没有精度损失。实时操作需要 ≥ 2027 FPS (PRF = 1664 行/秒 $\times$ 19950 样本/行)；使用四个 CPU 线程的 DPU 推理 (不包括预处理 & NMS)，实现了 3527 ± 23 FPS，超过了目标。

3.3. 哨兵-1 干涉宽模式

我们从上海港收集的手工标注的 IW 数据集包含 10 个大小为 20760×1617 的突发数据，分辨率为 5×20 米。我们将其中 8/1/1 个突发数据分别用于训练、验证和测试集。训练集中包含 1163 艘船和 460 台风力机；在排除近岸的船只后，测试集中包含 66 艘船和 19 台风力机。初步实验中，位于近岸的船只显示出显著的性能退化，可能是由于这些区域复杂且模糊的后向散射所致。因此，我们从最终评估中排除了这些船只。

由于在数据采集期间不断进行方位上的天线波束控制，并且所研究场景的性质更加复杂，IW 数据提出了额外的挑战。最初尝试使用我们的小输入量的模型处理原始 IW 数据未能获得足够的性能。结果，我们使用了距离压缩的数据。

表格 2 报告了检测指标和各类的 $F1_{30}$ (定量结果见图 3)；类别得分排除了其他类别的标签，以隔离每个类别的性能。我们最小的模型已经表现良好，并且通过增加裁剪大小和参数数量进一步提高了 $F1_{30}$ ，尽管收益趋于平稳——这可能是由于过拟合。经过人工检查，许多剩余错误是由于紧密靠近的船只，受到 NMS 限制，以及模糊标签所致。




Fig. 2. 左图：原始 Stripmap SAR 数据的实部，经过半调频平移以对齐 SLC 标签；右图：手动标注的 SLC 图像，叠加了网络后处理的检测结果（包含修改过的 Copernicus Sentinel 数据 [1]）。




Fig. 3. 左图：经过中心偏移校正的幅压缩 IW SAR 裁剪图（网络输入）（参见第 2 节）；右图：处理后的检测结果叠加在标记的 SLC 图像上（适用于 (M) 模型，包含修改后的哨兵数据 [1]）。

Table 2. 模型比较：对于我们的测试图像中的离岸船只的干涉宽数据的结果（距离压缩输入数据）。输入表示裁剪尺寸。

Size	Input	$F1_{30}$	Ship $F1_{30}$	Wind. $F1_{30}$
L	256	0.87 ± 0.01	0.77 ± 0.01	0.71 ± 0.04
M	256	0.87 ± 0.05	0.78 ± 0.05	0.78 ± 0.02
S	256	0.79 ± 0.01	0.56 ± 0.07	0.54 ± 0.06
S	128	0.72 ± 0.04	0.52 ± 0.02	0.51 ± 0.03

4. 讨论

我们在原始 Stripmap 和距离压缩的 IW 数据上进行了实验。对于 Stripmap，通过将原始输入移位半个调频脉冲大小，实现了优异的结果，绕过了计算昂贵的图像聚焦步骤，能够直接对原始 SAR 数据的小块进行预测。模型在参数和前向传递复杂度方面都保持紧凑，并且我们将其部署在 Zynq UltraScale+ MPSoC ZCU104 FPGA 上，展示了其对实时嵌入式处理的适用性。然而，此处使用的 Stripmap 场景相对简单，具有相似的后向散射，因此未来的工作应在更复杂的海洋条件和多样化环境下测试其鲁棒性。

在对 IW 数据的评估中，我们发现仅靠原始数据，与 Stripmap 数据相比，无法得到令人满意的结果。因此，我们进行距离压缩，从而提高了性能。我们将这种改进归因于目标能量更加集中，因此更容易通过我们神经网络的小视场识别。通过增加与我们 Stripmap 模型相比的输入裁剪大小和网络复杂性，我们在 IW 数据上实现了良好的性能。此外，我们成功地进行了目标分类，在船只和风车之间进行了二元分类。

我们方法的主要限制是难以检测到非常靠近岸边的船只，所以在最终评估中我们排除了这些情况。这种较低的性能可能是由于来自周围建筑和船只的强回波散射造成的，并且可能通过使用更多样化的训练数据来缓解。

Stripmap 和 IW 数据中观察到的局限性很大程度上

可以归因于数据集的可用性和质量。一个主要的挑战是缺乏足够大和多样化的标记原始 SAR 数据集，特别是在变化的海况下。即将发射的装有 AIS 跟踪天线的 Sentinel-1 卫星有望通过 AIS 数据关联实现自动标记，从而解决这一差距。此外，由于已有许多用于处理 SLC 图像的算法，未来的工作可以利用这些方法通过将基于 SLC 的检测与原始 SAR 数据对齐来生成大规模数据集，从而进一步扩展用于训练和评估的标记数据池。

我们展示了使用深度学习模型对原始 Stripmap 数据进行实时船只检测的可行性。此外，我们将我们的 Stripmap 模型部署在 Zynq UltraScale+ MPSoC ZCU104 FPGA 上，展示了其在资源受限环境中进行实时、车载处理的实际应用。对于 IW 数据，我们表明使用距离压缩数据和更大的输入尺寸可以提高检测和分类性能，使得船只和风车的二元分类成为可能。作者感谢 Sanath Muret、Max Ghiglione 和 Maris Tali 在 FPGA 支持和讨论方面的帮助。

REFERENCES

- [1] Copernicus Data Space Ecosystem. Copernicus data space ecosystem, 2024.
- [2] David J Crisp. The state-of-the-art in ship detection in synthetic aperture radar imagery. 2004.
- [3] Kevin De Sousa, Georgios Pilikos, Mario Azcueta, and Nicolas Floury. Ship detection from raw SAR echoes using convolutional neural networks. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2024.
- [4] Max Ghiglione, Ernesto Imbemomba, Salvatore D'Addio, Georgios Pilikos, Nicolas Floury, Marc Zimmermanns, Luis Mansilla Garcia, Nicolas Longépé, Roberto Del Prete, Stefan Graham, Mario

- Azcueta, and Martin Suess. Technology developments and activities at the European Space Agency for cognitive synthetic aperture radar payloads. In International Astronautical Congress , 2024.
- [5] Kaiming He, Xiangyu Zhang, Shaoqing Ren, and Jian Sun. Deep residual learning for image recognition. In Proceedings of the IEEE conference on computer vision and pattern recognition , 2016.
- [6] Itay Hubara, Yury Nahshan, Yair Hanani, Ron Banner, and Daniel Soudry. Improving post training neural quantization: Layer-wise calibration and integer programming. arXiv:2006.10518 , 2020.
- [7] Xilinx Inc. Vitis AI: AI Inference Development Platform , 2023.
- [8] Sushil Kumar Joshi, Stefan V Baumgartner, Andre BC da Silva, and Gerhard Krieger. Range-Doppler based CFAR ship detection with automatic training data selection. Remote Sensing , 2019.
- [9] Xiangguang Leng, Jin Wang, Kefeng Ji, and Gangyao Kuang. Ship detection in range-compressed SAR data. In IEEE International Geoscience and Remote Sensing Symposium , 2022.
- [10] Xiangguang Leng, Kefeng Ji, and Gangyao Kuang. Ship detection from raw SAR echo data. IEEE Transactions on Geoscience and Remote Sensing , 2023.
- [11] Jianwei Li, Jie Chen, Pu Cheng, Zhentao Yu, Lu Yu, and Cheng Chi. A survey on deep-learning-based real-time SAR ship detection. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing , 2023.
- [12] Georgios Pilikos, Mario Azcueta, Roberto Camarero, and Nicolas Floury. Raw data compression for synthetic aperture radar using deep learning. In Int. Workshop On-Board Payload Data Compression , 2022.
- [13] Georgios Pilikos, Mario Azcueta, Roberto Camarero, and Nicolas Floury. Raw SAR data compression with deep learning. In IEEE International Geoscience and Remote Sensing Symposium , 2024.
- [14] Joseph Redmon, Santosh Divvala, Ross Girshick, and Ali Farhadi. You only look once: Unified, real-time object detection. In IEEE conference on computer vision and pattern recognition , 2016.
- [15] William J Youden. Index for rating diagnostic tests. Cancer , 1950.
- [16] HongCheng Zeng, YuTong Song, Wei Yang, Tian Miao, Wei Liu, WeiJie Wang, and Jie Chen. An Incept-TextCNN model for ship target detection in SAR range-compressed domain. IEEE Geoscience and Remote Sensing Letters , 2024.
- [17] Tianwen Zhang and Xiaoling Zhang. ShipDeNet-20: An only 20 convolution layers and < 1-MB lightweight SAR ship detector. IEEE Geoscience and Remote Sensing Letters , 2020.