基于 Red Hat OpenShift AI 的 MLOps 辅助异常反射超表面设计

Wael Elshennawy

arXiv:2603.03981v1 [eess.SP] 4 Mar 2026

摘要—**将人工智能作为超表面设计工具加以集成，并实施深度学习模型，由于资源需求量大，在开发自动化解决方案时面临挑战。本文提出了一种网络层解决方案，用于根据终端用户目标配置此类环境，并支持底层物理层技术。本文采用红帽 OpenShift AI（RHOAI）技术，构建了一种用于设计异常反射器的架构，以支持智能无线电环境中的自动化机器学习运维（机器学习运维）框架。该架构旨在设计由标量表面阻抗表征的无损不透射超表面，通过利用作为适应度函数的局部功率守恒约束来优化 Floquet 模式的数量，从而实现最佳异常反射。超表面设计流程采用条件生成对抗网络（条件生成对抗网络）实现。扩展后的条件生成对抗网络结合代理模型，有助于实现高质量自由形态超表面设计，并为超表面设计流程及远场模型分析提供快速仿真工具。本文重点探讨构建此类系统所面临的挑战，以及潜在的抽象层。所提模型的训练准确率表明，在红帽OpenShift的容器化环境中部署具有可行性和优势，相较之下，文献中报告的其他 ResNet-50 部署方案则不及这一方案。**

索引词—**超表面、智能无线电环境、可编程无线环境、智能超表面、可重构智能表面、HyperSurfaces、软件定义网络。**

I. 引言

预编程和可重构超表面为既有技术的发展作出了重要贡献。然而，它们仍面临一项严峻挑战：如何快速、自动地适应用户特定的功能和场地特定的需求。将智能融入超表面，对于使其适应真实世界的环境条件和外部刺激至关重要[1], [2], [3]。其主要目标是开发能够高效处理电磁（EM）波并自主执行复杂任务的智能超表面。为实现这一目标，智能超表面必须整合三个基本组成部分：应用、智能算法和可调超表面，并将它们组织成闭环框架 [4]。

由于构成超原子之间相互依存且存在耦合，仅凭某些几何原理无法准确表征超表面的整体电磁响应。此外，自由形态超表面可能会产生二阶、三阶乃至更复杂阶次的高阶散射波，这使问题更加复杂；自由形态超表面设计过程需要表征大量具有不同物理和几何参数的超原子设计，这需要大量计算资源 [5]。因此，人们需要简化超表面的全局设计，以便实现智能算法层；这对于新一代智能超表面的发展至关重要。与设计单个单元或小规模超材料相比，解空间维度的增加带来了重大挑战。为实现理想性能，人们已采用非局域响应提出了不同方案，例如能量表面导引 [6], 、抑制寄生散射 [7],, 以及将深度学习网络与一种引入辅助表面波的方法相结合 [8]。

众多研究致力于将深度学习（DL）融入超表面设计，以提升其设计性能[9], [10], [8],，而超表面本质上受物理定律支配。利用神经网络处理与高维超表面相关的输入，对基于物理原理的数据生成、整理以及网络建模提出了严格要求。条件生成对抗网络有望以低成本设计具有复杂频率特性和偏振相关散射响应的超表面 [11]。条件生成对抗网络最令人振奋的特性之一，是能够发现文献中从未出现过的新几何结构 [12]。这表明，深度学习模型能够隐式学习麦克斯韦方程组中的物理关系，而非仅仅根据过往设计进行插值。因此，训练后的条件生成对抗网络模型可以按需生成满足指定电磁目标的超原子设计。条件生成对抗网络还采用了梯度惩罚方法，具有很高的稳定性，且易于收敛。

深度学习驱动的按需超表面设计领域取得了显著进展，因为它解决了传统数值仿真和基于物理学的方法在效率低下、耗时以及依赖实验知识方面的局限性 [13]。然而，智能超表面的快速发展也伴随着一些挑战 [12]。由此产生了几个关键问题，例如如何预先收集大量标注数据、频繁微调网络参数，以及如何有效处理自由度更高的目标。此外，样本收集和神经网络训练的过程本质上受限于预先定义的单个超表面，在应用于更大规模的问题时往往会失效 [14], [15]。

最终目标是自动部署智能超表面，以应用于复杂的

动态且不可预测的环境。仅使用可调谐的独立超表面无法满足这一需求；因此，必须为超表面集成一系列辅助功能，以构建完整的感知—决策—响应系统。重点在于实现现场学习以及在不同环境之间交换知识。Red Hat OpenShift AI（RHOAI）可支持此类部署，并通过在 OpenShift 之上提供受支持的 AI 工具，构建机器学习运维平台，以创建和交付生成式人工智能及预测模型，并自动化超表面的运行生命周期。这将使数据科学家和开发者能够高效协作，并创建可靠、可扩展且可复现的数据科学项目，以满足这一需求。

本文介绍了一种借助机器学习运维的超表面逆向设计方法，可根据所需波前快速完成设计。基于场优化，设计了由标量表面阻抗表征、用于实现完美异常反射的无损超表面。引入一组同极化表面波（SW），并对总切向场进行优化，使表面法向净功率密度处处最小，从而获得纯电抗性表面阻抗。深度学习模型由条件生成对抗网络的生成器模型和判别器模型组成，并额外采用代理模型作为电磁响应预测工具，以寻找具有相似电磁响应的多种结构。

机器学习运维采用一套实践方法和工具，用于管理超表面设计所用机器学习模型的整个生命周期，从而实现自动化、可复现性，并高效部署这一复杂设计流程。本文其余部分安排如下：第二节介绍问题表述并讨论所提设计框架的动机；第三节详细介绍所提出的设计框架流程，包括逆向条件生成对抗网络模型，以及基于 HyperSurface 的可编程无线环境模型，该模型融合了软件定义网络（SDN）基础设施的网络层；第四节讨论运用机器学习运维实现条件生成对抗网络模型自动化；第五节介绍由 RHOAI 实现的 ResNet 50 模型的性能指标，并将其与非容器化环境进行比较；第六节总结全文。

II. 问题表述

在广义反射定律所支配的异常反射器背景下，已有研究表明，随着偏转角增大，导向异常角的功率效率会显著降低 [16]。当入射波与反射波之和被定义为总场时，所得反射表面会呈现交替分布的有源区域和有损区域，但仍保持平均功率中性。对于 Ω-双各向异性超表面，在传播波（PWs）之外引入辅助倏逝波，并施加局部功率守恒约束，可得到无源、无损的表面规格，从而实现完美异常反射 [17]。一种保偏

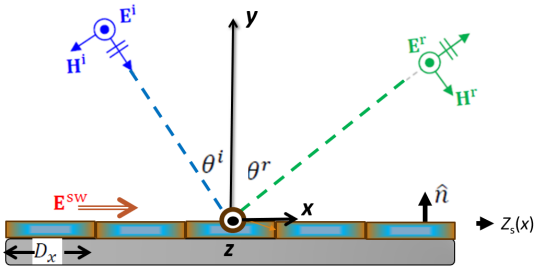


图 1. 异常反射器超表面在xz平面内对 TE^y 平面波的反射。表面波$\mathbf{E}^{SW}$与平面波同极化，改编自 [18]。

平面波的异常反射器如图 1 所示，其中，一束场为（$\mathbf{E}^i$, $\mathbf{H}^i$）的入射平面波照射到 xz 平面上的反射器表面，入射角为 θ^i。假设所有入射功率都以异常反射角 θ^r 完全反射，反射波的平面波场为（$\mathbf{E}^r$, $\mathbf{H}^r$）。

引入一组同极化表面波（SW），然后对总切向场（E_{tz}, H_{tz}）进行优化，以尽量减小垂直于表面的净功率密度，从而实现纯电抗性表面阻抗。优化表面波的数量，使表征反射表面的标量表面阻抗 $Z_s(x)$ 接近纯电抗性分布。无损条件等价于坡印廷矢量的法向分量满足 $S_y(x)$，如下文 [6] 所示。

$$S_y(x) = \frac{1}{2}\Re\mathfrak{e}\{E_{tz}H_{tx}^*\} = 0. \tag{1}$$

这种异常反射超表面有助于进一步理解设计条件下寄生反射的效率和能量分布。相比之下，自由形态超表面的传统数值方法耗时较长，且需要专业知识 [6] 。近期研究表明，深度学习有望显著加快并改进超表面设计 [19], [8], [20]。采用机器学习策略十分重要，因为它能够为生产就绪的推理服务创建可复用模式，并借助云原生工具和架构进一步实现整个机器学习模型生命周期的自动化。

III. 所提流程

需要一种方法来提高基于深度学习（DL）的可重构智能表面（RIS）设计的计算效率，并减少所需的训练量。这涉及一个深度学习模型和一种优化架构，该架构在人工神经网络（ANN）架构中利用基于物理的解析模型 [8]。本文提出了一种混合模型，其中训练数据集由基于物理的解析模型提供，从而减少所需训练数据集的规模并提高学习效率。这种基于深度学习模型的分析流程旨在通过迭代式综合分析实现高效综合 [21]。本文结合场优化技术开发了一种深度学习模型，用于异常反射器的宏观设计。

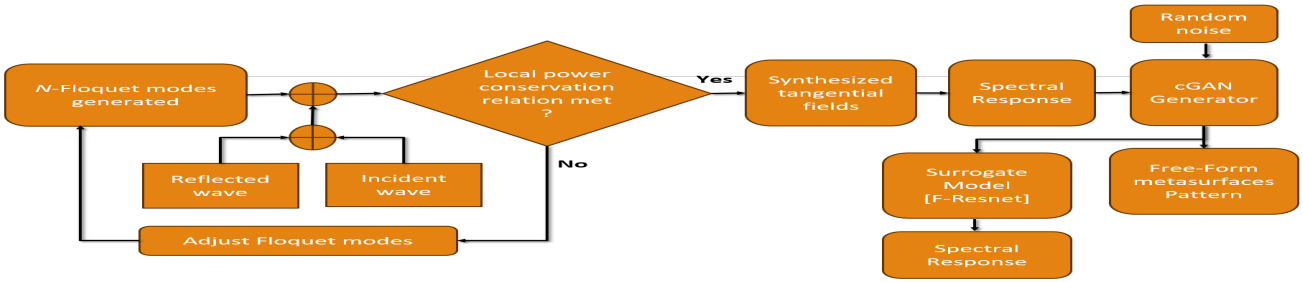


图 2. 用于超表面逆向设计的生成器及代理模型的训练过程。

该优化技术采用功率再分配适应度函数，以满足无损和无源超表面的要求。

神经网络模型的主要输入是合成的切向场，如图 2 所示。该网络用于计算超表面的自由形态图案。根据 Floquet 理论，选择结构的空间周期性（如图 1 所示）D_x，即可确定反射模态的传播方向。以入射角为 θ_i 的平面波照射无限周期超表面时，反射场定义为沿不同方向传播的平面波的叠加，其关系如 [17] 所示

$$sin\theta_{rn} = sin\theta_i + \frac{2\pi}{\kappa D_x} n, \tag{2}$$

其中，κ 是波数，θ_{rn} 是索引为 $n = 0$ 的传播谐波的反射角，±1，±2，.....。如图 2 所示，引入多个倏逝模态并对其进行定量控制，从而使垂直于表面的净功率密度处处最小，以获得纯电抗性表面阻抗。随后对总切向场进行优化，使其满足局部功率守恒关系。接着利用合成的切向场生成所需的光谱响应。条件生成对抗网络模型利用期望的光谱响应，引导并控制特定自由形态超表面的生成。添加上下文信息有助于条件生成对抗网络模型更好地构建潜在空间，生成更一致且符合预期的结果。

A. 条件生成对抗网络驱动的超表面逆向设计

超表面几何预测的逆向设计属于一对多问题，可能会产生多个与合成切向场相对应的图案。为了解决目标与设计之间的一对多关联问题，扩展的条件生成对抗网络模型由预训练代理模型 [22] 引导。该代理模型利用条件生成对抗网络的功能，自动设计具有所需光谱响应的自由形态超表面图案。它还可作为预测工具，用于分析超表面图案 [23]。超表面设计框架中的生成器网络由两个组件构成：一是用于根据超表面图案预测光谱响应的代理模型（Forward ResNet-50 [24]），

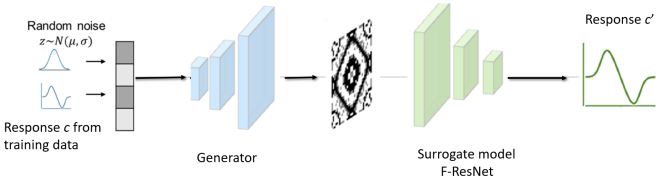


图 3. 条件生成对抗网络模型示意图，改编自 [25]。

二是遵循特定层与操作序列的生成器网络。该序列会根据所需响应生成图案，如图 3 所示。在训练过程中，从训练数据集采样得到的所需响应 c 会与从高斯分布 $N(\mu, \sigma)$ 中采样得到的随机噪声 z 拼接。拼接后的向量输入生成器，从而生成所需图案。 c和 c' 分别表示所需响应和代理模型生成的响应。

条件生成对抗网络的学习过程涉及两个神经网络——生成器和判别器——之间的对抗博弈。条件生成对抗网络模型的架构见 [25]。推理过程中仅使用生成器，并移除判别器。判别器通过评估真实图案与合成图案的分布距离来训练生成器。在成功完成训练后，判别器将无法区分生成器生成的批次与训练数据集 [12]。要生成初始超表面图案，需将符合高斯分布的随机噪声和目标响应输入生成器。采用代理模型计算该图案的响应。如果计算所得响应 c' 与目标响应 c 之间的误差低于预设阈值，则初始设计图案即成为最终设计。

超表面是引入可编程无线环境（PWE）的核心技术。利用软件能力调整超表面功能，超表面可支持多种电磁相互作用，这些相互作用被记为功能。一个相关示例是：支持6G的系统使用可重构智能表面，将无线电传播从不可控的随机现象转变为定制的网络参数 [26]。为满足这一要求，外部软件服务会计算并部署每个超表面的最优相互作用类型

以最佳方式满足通信设备的需求。这类软件定义超表面（SDM）将联网控制元件与自适应超表面相结合，从而将无线传播视为一种应用 [27], [28]。本文在此通过实现异常反射超表面来讨论反射功能。下一小节将介绍SDM的架构集成及其相关的复杂底层物理学。随后，提出软件抽象，使表面能够以不依赖物理学的方式进行相互作用。

B. 软件定义超表面与可编程无线环境

可编程无线环境通过在室内环境中的墙壁、天花板等平面物体上铺设瓦片（即具备网络互联能力的 HyperSurfaces 矩形面板）来构建 [29]。借助这项能力，中央服务器可以连接任意瓦片，获取其状态并自动设置其电磁功能。本文讨论物理层，并提出一种在可编程无线环境的多层架构中构建机器学习运维平台的方法。换言之，本文介绍了一种自动化解决方案，如图4所示，该方案将用户输入与可编程无线环境中的通信目标相结合，可无缝部署、监控并扩展机器学习模型，以用于实际应用。通过软件定义超表面（SDM）增强物理（PHY）层。软件定义超表面是一类联网超表面，配备了应用程序编程接口（API）和电磁编译器。API 可在抽象底层物理学的同时，获取 HyperSurface 的状态并设置其电磁功能 [30]。电磁编译器会将 API 回调转换为相应的有源元件状态。超表面能够适应不同的波特性，从而改变所需的输出功能。超表面的局部可调性使其每个构成单元都能够独立调节。通过对超表面的表面阻抗进行空间调制，还可实现其他功能。

电磁行为层和计算层旁边是通信协议栈，其中包含连接执行层、感知层、计算层与外部瓦片设备的连接方式。该层直接在计算硬件中实现，充当连接其他瓦片的网关，并使用任意通用协议 [32]。网关通常连接到软件定义网络（SDN）控制器，以通过电磁 API 接收电磁操控命令。文献 [33] 中讨论的软件定义网络（SDN）控制器通常依赖设备定位系统（DLS），通过了解平面布局图和超表面的位置来执行操作。超表面可利用 [34], [3] 中的机器学习模型寻找图路径，从而发挥这一作用。超表面开箱即用即可充当非常有效的设备定位系统，能够准确估计用户设备的位置，同时执行其他电磁功能。可编程无线环境（PWEs）还部署了一个信标，该信标也通过有线方式连接到 SDN 控制器；不过，此处的讨论主要局限于单个超表面瓦片的场景。由于 SDN 将控制平面与数据平面隔离，因此网络智能在逻辑上实现了集中化。

可编程无线环境（PWEs）/SDN 控制器支持主要的应用程序接口，即北向和南向接口。南向接口负责控制异构的可编程无线环境（PWEs）和 SDN 设备，包括可重构智能表面（RISs）及其他受管理的网络设备。它还为控制器组件提供统一的应用程序接口，并通过指定的适配器连接至可重构智能表面（RISs）的 SDM接口 [32]。北向接口负责向网络服务和管理功能提供“无线信道即服务”能力。北向接口用于向更高层的网络管理应用程序和服务公开 SDN 控制器的功能，如\ref{Fig4}所示。这些接口使外部应用程序能够与 SDN 控制器交互、请求网络服务并检索信息。北向接口支持网络管理任务的可编程化和自动化，并促进其与编排系统、云平台及其他管理工具的集成。自动化利用北向接口进行编排，并利用南向接口以编程方式配置、管理和实时优化流量。

SDN控制器支持控制器应用程序与交换机内转发表之间的标准接口。因此，它为网络虚拟化提供了天然环境。应用程序通常位于私有云或公有云中，使移动用户能够随时随地访问可重构智能表面。然而，这种架构设置-I 并不适用于云计算的高领域应用场景（图 4 中虚线左侧）。它无法管理需求，例如自动化等。在云范式下，提供新颖的端到端服务和应用程序已变得更加复杂且成本更高。为满足云计算范式下对可管理性和自动化的并行需求，通过集成 SDN 技术与 RHOAI 平台，可进一步实现在动态 IT范式中提供自动化、可靠的应用交付等新型服务。

IV. 用于自动化超表面设计的机器学习运维

最终愿景是构建超表面互联网（IoM） [35], [36], ，并对材料的电磁行为实现自动化控制。SDN控制器支持高级应用程序接口，可对网络本身进行抽象，使开发人员无需分别处理网络设备，而是能够对整个网络进行统一管理。因此，网络管理员可以借助 SDN控制器，通过组织软件来引入新功能，从而轻松影响网络切片的逻辑映射。这使我们能够采用一套实践和工具，管理部署在 RHOAI 平台上的深度学习模型的整个生命周期。由此，我们可以将其应用于超表面设计，实现自动化、可复现性和高效部署。

RHOAI架构如图 4 所示，用于构建机器学习运维平台，并在 OpenShift [37]之上借助人工智能工具包交付条件生成对抗网络模型。模型服务利用项目/工作台中的数据连接组件，从兼容 S3 的存储中下载条件生成对抗网络模型。模型下载完成后，会通过

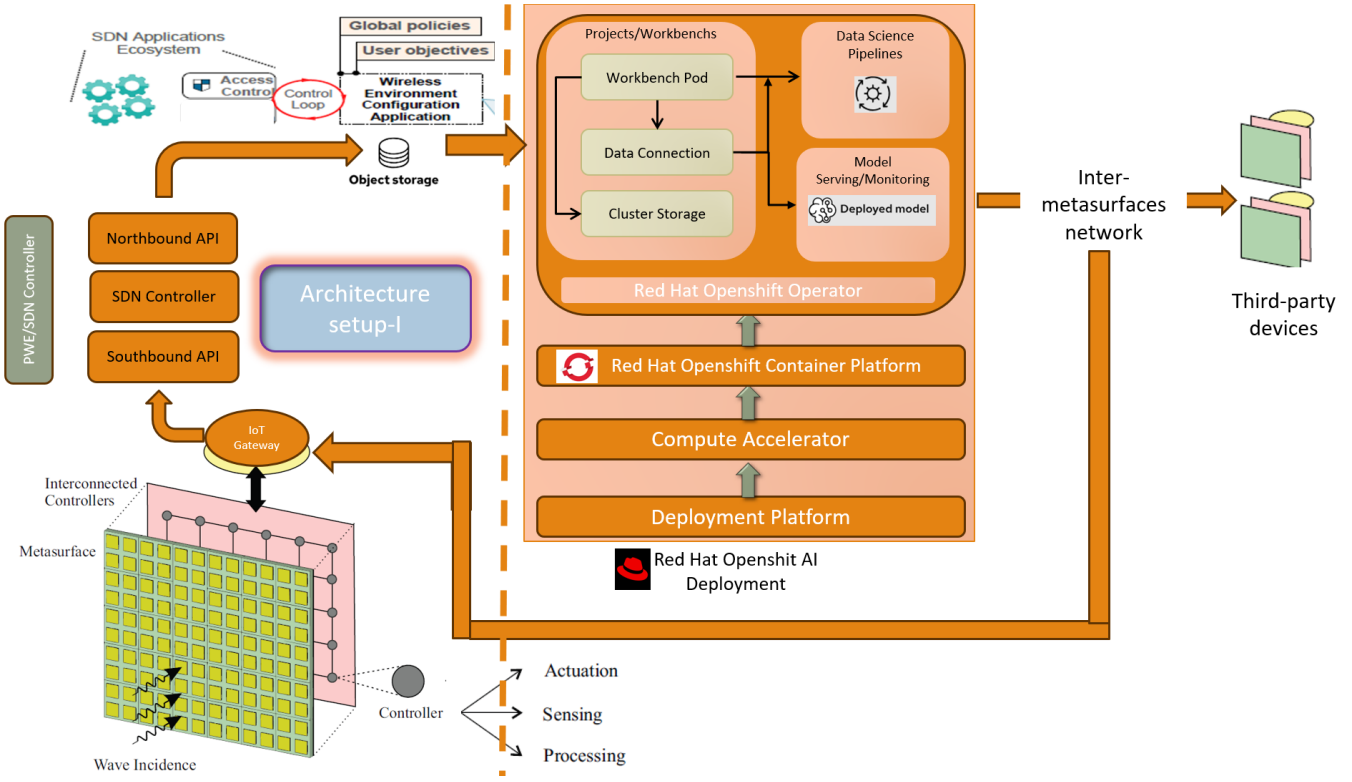


图 4. 通过集成 RIS/HyperSurfaces、软件定义网络范式和 RHOAI，在可编程无线环境中自动化设计超表面的机器学习运维工作流。改编自 [31]

REST API 将其提供使用。机器学习模型的自动化由数据科学流水线完成，该工作流包括：从由 SDN控制器通过可重构智能表面采集的真实数据所馈入的数据存储中收集真实数据、进行数据清洗、训练条件生成对抗网络模型、评估模型，最后将模型保存到 S3 存储桶中，以便后续检索。条件生成对抗网络模型的可扩展性由工作台管理，工作台会自动调整 Pod 数量，以适应工作负载的变化。集群存储通过使用持久卷声明（PVC）确保数据得以保留，以便在工作台重启时恢复数据。最后，仪表板和模型监控可以持续跟踪数据科学工作负载的性能，并修复任何潜在问题。RHOAI 通过将数据科学工具与开发运维原则和 Kubernetes 编排相结合，简化了条件生成对抗网络模型的整个机器学习运维生命周期。

V. 性能指标

要将 RHOAI 与其他非容器化环境的计算效率进行比较，需要针对特定数据集和硬件配置进行基准测试。性能比较所用的数据集为 ImageNet。它广泛用于计算机视觉领域的训练和基准测试，尤其适用于图像分类和目标检测任务 [38] 。RHOAI 的主要评估指标是与非容器化环境相比的“性能差值”，即平台开销、优化等因素。由 ResNet-50 构建的、由 cGAN 驱动的逆向超表面设计，其计算效率涉及特征提取与电磁响应预测工具的代理模型相结合，而电磁响应预测工具的代理模型会因模型架构、硬件和实现细节等因素而略有不同。此外，复杂度还受数据集大小、训练轮数和批次大小影响。使用 OpenShift 4.13+（OpenShift AI 的基础）实现的 ResNet-50 在 ImageNet 上的训练结果与裸机结果相差不到 0.4%，性能接近原生水平 [39]。

Jia 等人使用 2,048 个图形处理器，在 6.6 分钟内完成了 ResNet-50 模型训练 [40]。Ying 等人使用 1,024 个 TPU v3 处理器，在 1.8 分钟内完成训练 [41] 。Mikami 等人报告称，使用 Tesla V100 处理器，以 55,296 的小批量大小训练 ResNet-50 需要 2.0 分钟 [42] 。[43] 报告称，增大小批量大小可略微缩短训练时间。对于标准的 OpenShift AI 单节点训练，Top-1 准确率介于 75.08% 至 76.15% 之间。显然，与其他模型部署相比，其训练时间和批次大小最小。近期，通过知识蒸馏或专门的训练方案（如 MEAL V2）等高级优化技术，原始 ResNet-50 的 Top-1 准确率已提升至 80% 以上。表 I 总结了各模型在准确率和训练时间等关键性能指标上的表现。

RHOAI 还支持通过以下 OpenShift AI 组件实时监控训练和测试误差。模型监控：集成式仪表板可跟踪在线服务模型的漂移检测和准确率损失，并将实时推理数据与原始训练

作者	批次大小	处理器	深度学习库	时间（分钟）	准确率（%）
Jia 等人 [40]	65,536	Tesla P40 × 2,048	TensorFlow	6.6	75.8
Ying 等人 [41]	65,536	TPU v3 × 1,024	TensorFlow	1.8	75.2
Mikami 等人 [42]	55,296	Tesla V100 × 3,456	NNL	2.0	75.29
Yamazaki 等人 [43]	81,920	Tesla V100 × 2,048	MXNet	1.2	75.08
RHOAI 标准单节点训练	1,024	4x NVIDIA A10G	PyTorch 和 TensorFlow	¡ 1	75.08-76.15

表 I 使用 IMAGNET 上的 ResNet-50 时的训练时间和 Top-1 验证准确率。

分布进行比较。流水线：数据科学家可在 OpenShift AI 流水线的 Runs 选项卡中查看训练生命周期内生成的训练/验证误差曲线（例如，均方误差或平均绝对误差）。弹性。

VI. 结论

本文提出了一种用于可编程无线环境（PWEs）中智能超表面的多层架构，由算法层、可调超表面层和应用层组成，并探讨了利用 RHOAI 平台实现该架构的方法。RHOAI 能够自动化并简化将机器学习模型集成到软件开发流程、生产部署、监控、重新训练和重新部署中的迭代过程，从而持续保持预测准确率。本文讨论了异常反射器和条件生成对抗网络模型（cGAN model），强调了其在自由形态超表面的前向预测和逆向设计中的潜力。所提出的自动化解决方案受益于云原生边缘计算，将边缘处理的速度与云原生敏捷性相结合，从而实现高效、可扩展且安全的分布式应用。此外，本文指出了当前面临的挑战，并阐述了未来的发展方向，以推动智能超表面时代的到来。由于所提出的实现方式简化了真实环境中可重构超表面的机器学习运维，因此该模型的实际应用仍需进一步研究。这些技术——微服务和超表面——的融合，是 6G 和开放式无线接入网（O-RAN）框架下的活跃研究主题之一。本文强调了采用机器学习策略、为生产就绪的推理服务创建可复用模式，以及在智能超表面领域利用云原生工具和架构自动化机器学习模型生命周期的重要性。

参考文献

[1] Christos Liaskos、Shuai Nie、Ageliki Tsioliaridou、Andreas Pitsillides、Sotiris Ioannidis和Ian Akyildiz，“通过软件定义超表面环境实现无线通信”，载于*2018*年*IEEE*第*19*届“无线、移动与多媒体网络世界”国际研讨会（*WoWMoM*）。IEEE，2018年，第14–15页。[2] Han Qing Yang、Jun Yan Dai、Hui Dong Li、Lijie Wu、Zi Hang Shen、Qun Yan Zhou、Meng Zhen Zhang、Si Ran Wang、Zheng Xing Wang、Jun Wei Wu等，“面向复杂环境中智能无线通信的自适应可编程超表面”，《自然·通讯》，第16卷，第1期，第6070页，2025年。[3] Odysseas Tsilipakos、Anna C Tasolamprou、Alexandros Pitilakis、Fu Liu、Xuchen Wang、Mohammad Sajjad Mirmoosa、Dimitrios C Tzarouchis、Sergi Abadal、Hamidreza Taghvaee、Christos Liaskos等，“迈向智能超表面：从全局可调超表面到具有嵌入式控制器网络的软件定义超表面的进展”，《先进光学材料》，第8卷，2000783，2020年17，期 页。

[4] Christos Liaskos、Ageliki Tsioliaridou、Andreas Pitsillides、Sotiris Ioan- nidis 和 Ian Akyildiz，《利用任意表面实现无线通信新范式》，*ACM*通讯，第61卷，第11期，第30–33页，2018年。[5] Ana D´ıaz-Rubio 和 Sergei A Tretyakov，《异常反射超表面的宏观建模：角度响应与远场散射》，*IEEE*天线与传播汇刊，第69卷，第10期，第6560–6571页，2021年。[6] Ana D´ıaz-Rubio、Viktar S Asadchy、Amr Elsakka 和 Sergei A Tretyakov，《从广义反射定律到完美异常反射器的实现》，《科学进展》，第3卷，第8期，第e1602714页，2017年。[7] Mostafa Movahediqomi、Yongming Li、Grigorii Ptitcyn、Viktar Asadchy 和 Sergei Tretyakov，《在可重构智能表面中同时实现完美异常反射与到达角感知》，《先进光学材料》，第13卷，第13期，第2403033页，2025年。[8] Chen Niu、Mario Phaneuf、Tianke Qiu 和 Puyan Mojabi，《一种基于深度学习、根据所需远场指标设计超表面的方法》，*IEEE*天线与传播开放期刊，第4卷，第641–653页，2023年。[9] Manna Dai、Yang Jiang、Feng Yang、Xinxing Xu、Weijiang Zhao、My Ha Dao 和 Yong Liu，《Slmgan：利用生成对抗网络和对称自由形态图案进行单层超表面设计》，《应用软计算》，第130卷，第109646页，2022年。[10] Wei Ma、Feng Cheng、Yihao Xu、Qinlong Wen 和 Yongmin Liu，《基于采用半监督学习策略的深度生成模型的超材料概率表示与逆向设计》，《先进材料》，第31卷，第35期，第1901111页，2019年。[11] Panithan La-aiddee、Paramin Sangwongngam、Lunchakorn Wuttisit- tikulkij 和 Pisit Vanichchanunt，《一种基于生成对抗网络的毫米波频段反射型超表面单元合成方法》，载于*2024*年电路/系统、计算机与通信国际技术会议*(ITC-CSCC)*，2024年，第1–5页。[12] John A Hodge、Kumar Vijay Mishra 和 Amir I Zaghloul，《面向未来通信的可重构超表面深度逆向设计》，*arXiv*预印本 *arXiv:2101.09131*，2021年。[13] Chen Niu、Mario Phaneuf、Tianke Qiu 和 Puyan Mojabi，《一种基于深度学习、根据所需远场指标设计超表面的方法》，*IEEE*天线与传播开放期刊，第4卷，第641–653页，2023年。[14] Yuetian Jia、Chao Qian、Zhixiang Fan、Tong Cai、Er-Ping Li 和 Hongsheng Chen，《一种用于智能超表面设计与组装的知识继承学习方法》，《*Light*：科学与应用》，第12卷，第1期，第82页，2023年。[15] Borui Xu、Jingzhu Shao、Xiangyu Zhao、Haishan Xu、Yudong Tian、Nanxi Chen、Jielin Sun、Han Lin、Qiaoliang Bao、Yiyong Mai 等，《基于深度学习、以全波精度逆向设计大规模超表面》，《激光与光子学评论》，第e03115页，2025年。[16] V. Asadchy、M. Albooyeh、S. Tcvetkova、Y. Ra’di 和 S. A. Tretyakov，《实现折射与反射完美且全面控制的超表面》，载于*2016*年第十届微波与光学先进电磁材料国际大会 *(METAMATERIALS)*，2016年，第364–366页。[17] Do-Hoon Kwon 和 Sergei A. Tretyakov，《利用正交极化表面波对不透射表面进行完美反射控制》，《物理评论*B*》，第96卷，第085438页，2017年8月。[18] Do-Hoon Kwon，《基于高效表面场优化、用于异常反射的无损标量超表面》，*IEEE*天线与无线传播快报，第17卷，第7期，第1149–1152页，2018年。[19] Parinaz Naseri、Stewart Pearson、Zhengzheng Wang 和 Sean V Hum，《一种结合机器学习与优化、用于非均匀双各向异性超表面逆向设计的方法》，*IEEE*天线与传播汇刊，第70卷，第7期，第5105–5119页，2021年。[20] Qian Zhang、Che Liu、Xiang Wan、Lei Zhang、Shuo Liu、Yan Yang 和 Tie Jun Cui，《各向异性数字编码超表面的机器学习设计

超表面》，《先进理论与仿真》，第2卷，第2期，第1800132页，2019年。[21] Karim Achouri 和 Christophe Caloz，《电磁超表面的设计、概念与应用》，纳米光子学，第7卷，第6期，第1095–1116页，2018年。[22] Muhammad Abdullah 和 Slawomir Koziel，《用于宽带雷达散射截面缩减的棋盘超表面代理辅助设计》，IEEE Access，第9卷，第46744–46754页，2021年。[23] Guoqing Jing、Peipei Wang、Haisheng Wu、Jianjun Ren、Zhiqiang Xie、Junmin Liu、Huapeng Ye、Ying Li、Dianyuan Fan 和 Shuqing Chen，《用于超表面逆向设计的神经网络代理模型》，Photon. Res.，第10卷，第6期，第1462–1471页，2022年6月。[24] “resnet50 — Torchvision 主文档 — docs.pytorch.org”，https://docs.pytorch.org/vision/main/models/generated/torchvision.models.resnet50.html，[访问日期：01-03-2026]。[25] Manna Dai、Yang Jiang、Feng Yang、Joyjit Chattoraj、Yingzhi Xia、Xinx- ing Xu、Weijiang Zhao、My Ha Dao 和 Yong Liu，《一种用于自由形态超表面设计参数优化的代理辅助扩展生成对抗网络》，神经网络，第180卷，106654，2024年，第。[26] JungSook Bae、Waqas Khalid、Anseok Lee、Heesoo Lee、Song Noh 和 Heejung Yu，《RIS赋能的6G无线网络安全传输概述》，Digital Communications and Networks，第10卷，第6期，第1553–1565页，2024年。[27] Christos Liaskos、Shuai Nie、Ageliki Tsioliaridou、Andreas Pitsillides、Sotiris Ioannidis 和 Ian Akyildiz，《通过软件控制超表面实现无线通信新范式》，IEEE通信杂志，第56卷，第9期，第162–169页，2018年。[28] Alexandros Pitilakis、Anna C Tasolamprou、Christos Liaskos、Fu Liu、Odysseas Tsilipakos、Xuchen Wang、Mohammad Sajjad Mirmoosa、Kypros Kossifos、Julius Georgiou、Andreas Pitsilides 等，《软件定义超表面范式：概念、挑战与前景》，载于2018年第12届新型波现象人工材料国际大会（超材料）。IEEE，2018年，第483–485页。[29] Ian F Akyildiz、Ahan Kak 和 Shuai Nie，《6G及未来：无线通信系统的前景》，IEEE Access，第8卷，第133995–134030页，2020年。[30] Christos Liaskos、Ageliki Tsioliaridou、Shuai Nie、Andreas Pitsillides、Sotiris Ioannidis 和 Ia n F. Akyildiz，《可编程无线环境的网络层建模与配置》，IEEE/ACM网络汇刊，第27卷，第4期，第1696–1713页，2019年。[31] C. Liaskos、A. Tsioliaridou、A. Pitsillides、S. Ioannidis 和 I. Akyildiz，《利用任意表面实现无线通信新范式》，Commun. ACM，第61卷，第11期，第30–33页，2018年10月。[32] Christos Liaskos、Lefteris Mamatas、Arash Pourdamghani、Ageliki Tsio- liaridou、Sotiris Ioannidis、Andreas Pitsillides、Stefan Schmid 和 Ian F Akyildiz，《软件定义可重构智能表面：从理论到端到端实现》，IEEE会刊，第110卷，第9期，第1466–1493页，2022年。[33] Christos Liaskos、Shuai Nie、Ageliki Tsioliaridou、Andreas Pitsillides、Sotiris Ioannidis 和 Ian Akyildiz，《通过软件控制超表面实现无线通信新范式》，IEEE通信杂志，第56卷，第9期，第162–169页，2018年。[34] Wael Elshennawy，《基于概率贝叶斯神经网络的传统共质数阵列波达方向估计》，International Journal of Computer Vision and Signal Processing 14 (1), 8，2024年。[35] Paweł Sroka，《面向6G无线通信的可重构智能表面：原理、部分应用案例与挑战》，载于2023年第16届信号处理与通信系统国际会议（ICSPCS），2023年，第1–2页。[36] Sarah Basharat、Maryam Khan、Muhammad Iqbal、Umair Sajid Hashmi、Syed Ali Raza Zaidi 和 Ian Robertson，《探索面向6G的可重构智能表面：最新进展与未来方向》，IET Communications，第16卷，第13期，第1458–1474页，2022年。[37] Ross Brigoli 和 Faisal Masood，《使用红帽OpenShift进行机器学习运维：云原生方法》，Packt Publishing Ltd，2024年。[38] Ruichao Zhu、Tianshuo Qiu、Jiafu Wang、Sai Sui、Chenglong Hao、Tong- hao Liu、Yongfeng Li、Mingde Feng、Anxue Zhang、Cheng-Wei Qiu 等，《通过迁移学习快速实现功能超表面的相位到方向图逆向设计范式》，《自然·通讯》，第12卷，第1期，第2974页，2021年。[39] Diane Feddema，《使用MLPerf Training v3.1量化超微a+ 服务器上红帽OpenShift的机器学习（ML）训练性能》，2023年11月。[40] Xianyan Jia、Shutao Song、Wei He、Yangzihao Wang、Haidong Rong、Feihu Zhou、Liqiang Xie、Zhenyu Guo、Yuanzhou Yang、Liwei Yu 等，“采用混合精度的高可扩展性深度学习训练系统：四分钟训练 ImageNet”，*arXiv* 预印本 *arXiv:1807 11205*，2018。.[41] Chris Ying、Sameer Kumar、Dehao Chen、Tao Wang 和 Youlong Cheng，“超级计算机规模的图像分类”，*arXiv* 预印本 *arXiv:1811.06992*，2018。[42] Hiroaki Mikami、Hisahiro Suganuma、Yoshiki Tanaka、Yuichi Kageyama 等，“大规模分布式随机梯度下降：瞬间完成 ImageNet/ResNet-50 训练”，*arXiv* 预印本 *arXiv:1811.05233*，2018。[43] Masafumi Yamazaki、Akihiko Kasagi、Akihiro Tabuchi、Takumi Honda、Masahiro Miwa、Naoto Fukumoto、Tsuguchika Tabaru、Atsushi Ike 和 Kohta Nakashima，“另一种加速随机梯度下降方法：在 74.7 秒内完成 ImageNet 上的 ResNet-50 训练”，*arXiv* 预印本 *arXiv:1903.12650*，2019。