

面向神经网络架构自主演进的联邦协同遥感场景分类

黎健钊¹, 王善峰², 杨瑞², 唐泽栋¹, 周宇³, 公茂果^{3,4}

1. 西安电子科技大学 广州研究院, 广州 510555;
2. 西安电子科技大学 网络与信息安全学院, 西安 710071;
3. 西安电子科技大学 电子工程学院, 西安 710071;
4. 内蒙古师范大学 人工智能学院, 呼和浩特 010028

摘要: 现有联邦遥感场景分类方法通常预设客户端的网络架构固定, 忽略了卫星、无人机等设备在算力、存储与能源供应上的显著异构性, 导致模型在资源受限终端难以适配部署, 限制了联邦系统的实用效率。鉴于此, 为探究支持神经网络架构在联邦框架下自主演化的协同方法, 本文提出一种基于路径与数据协同采样的神经网络搜索方法。该方法采用“一次训练, 多次使用”的神经网络架构搜索训练范式, 通过路径与数据双维度协同采样机制实现客户端的个性化适配。在超网的协同训练阶段, 各客户端通过梯度范数引导的路径采样动态筛选关键子网架构, 基于梯度上界的数据采样聚焦高价值样本, 大幅降低超网训练与通信成本; 在子网多方部署阶段, 通过进化算法基于本地数据搜索验证精度最优的个性化网络架构。此外, 在4个基准异构遥感场景分类数据集上的实验验证结果表明, 该方法在非独立同分布条件下显著优于固定架构与主流剪枝方法, 能在保护数据隐私前提下为异构客户端协同演化出轻量高性能专属网络架构, 有效提升了联邦遥感系统的部署可行性与整体性能。

关键词: 联邦学习, 遥感场景分类, 神经网络架构搜索, 演化计算, 协同学习与优化

中图分类号: TP753/P2

引用格式: 黎健钊, 王善峰, 杨瑞, 唐泽栋, 周宇, 公茂果. 2026. 面向神经网络架构自主演进的联邦协同遥感场景分类. 遥感学报, 30(5): 1498-1509

Li J Z, Wang S F, Yang R, Tang Z D, Zhou Y and Gong M G. 2026. Federated neural architecture autonomous evolution for collaborative remote sensing scene classification. National Remote Sensing Bulletin, 30(5): 1498-1509 [DOI: 10.11834/jrs.20265223]

1 引言

遥感影像场景分类通常基于对地观测获取的遥感数据, 利用计算机视觉与模式识别方法, 依据图像的整体语义内容将其自动归类至预定义的土地覆盖类别的过程(钱晓亮等, 2018)。作为遥感图像解译的基础任务, 遥感场景分类对于城市规划、环境监测、灾害评估等实际应用具有重要意义(Cheng等, 2020)。

近年来, 基于数据驱动的深度学习方法在遥感场景分类任务中取得了显著成果, 但是深度模型的训练往往受限于集中式训练范式(姚艳清等,

2021; 孙显等, 2022)。在集中式学习范式下, 构建一个具备广域覆盖能力与强泛化性能的遥感深度模型, 参与方必须将各自私有遥感数据迁移至中央服务器执行统一训练。但是, 在现实应用中, 遥感场景数据往往是高度敏感的, 涉及到地区发展规划、生态环境监控、国家国防安全等隐私信息(Wang等, 2024; Büyüktaş等, 2024)。集中式学习强制要求原始数据物理聚合, 其本质是通过打破数据空间隔离性实现全域特征整合, 但同步也引发了数据主权归属冲突与隐私泄露隐患(Li等, 2020)。

联邦学习, 作为一种新兴的分布式机器学习

收稿日期: 2025-06-23; 预印本: 2026-02-02

基金项目: 国家自然科学基金(编号: 62506283, 62476210); 国家资助博士后研究人员计划(编号: GZC20250166); 内蒙古生态安全智能监管关键技术研发与示范应用项目(编号: 2025KJTW0026)

第一作者简介: 黎健钊, 研究方向为协同学习与优化遥感影像解译。E-mail: lijianzhao@xidian.edu.cn

通信作者简介: 公茂果, 研究方向为协同学习与优化遥感影像解译。E-mail: gong@icece.org

范式, 允许多个数据持有方在不共享原始本地数据的前提下协同训练全局模型, 能在一定程度上解决了数据隐私保护问题。在联邦学习框架下, 各参与方(客户端)基于本地数据训练局部模型, 仅将模型参数或梯度上传至中央服务器进行全局聚合, 从而在保护数据隐私的同时实现模型性能的提升(杨强, 2019)。联邦学习的快速发展为解决遥感数据孤岛、隐私保护及跨机构协作提供了新思路。目前联邦遥感场景分类方兴未艾, Ben Youssef等(2024)将FedAvg应用于场景分类中, 并探讨了卷积神经网络与Transformer架构作为局部模型的协同平均聚合性能。PMPFSL算法(Wang等, 2024)提出了面向遥感场景分类的隐私保护个性化多方小样本学习框架, 结合个性化自适应蒸馏方案与多尺度特征匹配网络, 实现多方参与者协同小样本训练个性化模型。MPCL算法(Li等, 2024)在本地模型训练引入正则化项, 使模型既适配本地数据分布, 又保持与全局模型的关联性。HAPF算法(Hu等, 2025)提出了一种异构感知的个性化联邦剪枝框架, 通过基于特征的滤波器冗余评估和自适应异构聚合, 实现高效遥感场景分类。

总体而言, 现有的相关工作(Ben Youssef等, 2024; Li等, 2024; Wang等, 2024; Büyüktaş等, 2024; Hu等, 2025)主要是在联邦聚合方法与局部网络架构训练范式上进行结合, 在针对实际的遥感应用需求仍有改进空间。现阶段的方法假设各客户端参与聚合的网络架构是固定的, 这一强约束忽略了遥感场景中客户端设备(如卫星、无人机、地面站)计算能力、存储空间和能源供应的显著异构性, 限制了模型在资源受限终端上的适应性部署。因此, 亟需发展能够动态适应客户端数据和算力异质性的联邦遥感新范式, 在保护各方数据隐私的前提下, 协同探索更轻量、计算效率更高且与各客户端本地数据特性相匹配的最优网络架构, 在保障全局模型性能的同时, 显著提升复杂联邦遥感系统在实际部署场景下的可行性、效率和整体性能。

针对上述问题, 本文提出了一种基于路径与数据协同采样的联邦神经架构搜索方法, 采用“一次训练, 多次使用”的搜索范式, 旨在突破多方协同学习中架构固定约束, 实现联邦框架下神经网络结构的自主适配与演化, 为各客户端

生成轻量化且契合本地数据分布的专属模型。首先, 在超网协同训练阶段引入梯度范数引导的路径采样机制, 动态筛选关键子网架构, 使各客户端仅在重要子网上进行训练, 有效降低计算资源消耗; 其次, 实施基于梯度上界的数据采样策略, 优先训练对模型优化贡献度更高的样本, 降低超网梯度方差并提升子网性能一致性; 最后, 在子网部署阶段结合进化搜索算法, 依据各客户端本地数据特性搜索验证精度最优的个性化子网结构。并在4个基准联邦异构遥感场景分类数据集上进行实验验证, 将本文方法与固定神经网络架构及主流剪枝方法进行对比, 验证其在非独立同分布条件下的性能优越性, 并展示其作为联邦遥感系统可落地部署方案的潜力。

2 研究方法

2.1 问题建模

在联邦学习环境下, 假设有 K 个客户端, 每个客户端 k 拥有本地数据集 D_k , 且各客户端间不共享原始数据。现有的联邦神经架构(Zhang等, 2022; Liu等, 2024; Li等, 2025a)搜索旨在从预定义的搜索空间 A 中找到一个全局最优架构 α^* , 使其在所有客户端上的平均性能最大化。然而, 由于遥感数据的空间异质性和分布差异性, 单一全局架构难以满足各客户端的个性化需求。

本研究提出的方法采用“一次训练, 多次使用”的神经网络架构搜索范式(Zhang等, 2021; Chen等, 2023), 假设需要训练的超网为 N , 权值为 ω , 训练过程中, 客户端 k 采样子网 α_k 的概率分布为 $p_k(A)$, 采样数据 $(\mathbf{x}_k, \mathbf{y}_k)$ 的概率分布为 $q_k(A)$ 。每个客户端的优化目标是通过迭代采样和用训练数据 D_k^{train} 训练采样得到的子网, 来自演进获得最适合本地的架构。因此, 超级网络的优化目标为

$$\omega^* = \arg \min_{\omega} \sum_{k=1}^K \frac{n_k}{n} E_{\alpha_k \sim p_k(A), (\mathbf{x}_k, \mathbf{y}_k) \sim q_k(D_k^{\text{train}})} \left(L \left(N(\mathbf{x}_k, \alpha_k; \omega_{\alpha_k}), \mathbf{y}_k \right) \right)$$

式中, n_k 是客户端 k 的数据样本数, $n = \sum_{k=1}^K n_k$ 是所有客户端的总数据量。

在子网搜索阶段, 在继承权重 ω^* 的超网络通过演化优化搜索最佳子网 α^* , 种群个体的适应度 P

为子网在每个客户端验证集 D_k^{val} 上的评估性能。每个客户端的子网最优架构搜索目标如下：

$$\alpha_k^* = \arg \max_{\alpha_k \in A} E_{(x_k, y_k) \sim q_k(D_k^{\text{val}})} \left(P \left(N(x_k, \alpha_k; \omega_{\alpha_k}^*), y_k \right) \right)$$

搜索过程中子网性能的衡量依赖于继承的超网权重，所以超网中子网的排名的一致性至关重要，而超网训练过程中的梯度方差是影响子网排名一致性的关键因素。为降低梯度方差，提高子网排名一致性，需要优化路径采样分布 $p_k(A)$ 和数据采样分布 $q_k(D_k^{\text{min}})$ 。具体公式如下：

$$p_k^* = \arg \min_{p_k} V(d(p_k))$$

$$q_k^* = \arg \min_{q_k} V(d(q_k))$$

式中， $d(p_k)$ 和 $d(q_k)$ 分别是关于路径采样分布和数据采样分布的梯度方差函数， $V(\cdot)$ 表示方差算子。通过最小化这两个方差函数，可以确保超网训练过程中重要子网架构和关键数据样本获得充分训练，从而提高子网排名的一致性。

2.2 研究框架概述

本文所提出的基于路径和数据联合采样的联邦神经架构搜索框架如图1所示。该方法当中的客户端无法共享隐私数据，同时搜索空间所涉及的超网结构也主要分为两个单元，但与基于梯度的神经架构搜索单元略有不同，具体如下：(1) 可搜索单元。可搜索单元是方法中超网的核心搜索

单元，用于动态选择不同的网络架构，以实现神经架构搜索。该单元的特殊之处在于其内部的计算方式并非固定，而是由搜索空间和采样架构决定的。每个可搜索单元由多个计算节点组成，每个节点间可以选择不同的操作，例如标准卷积、深度可分离卷积、池化操作等，以适应不同的遥感场景任务需求。通过该模块，超网能够在不同深度动态调整网络架构，从而优化计算性能和模型表达能力。此外，可搜索单元采用了灵活的前向传播机制，根据给定的架构选择不同的计算路径，使得每轮训练时网络架构可以不断更新，以探索最优的架构配置。(2) 降维单元。降采样单元主要用于减少特征图尺寸，提高计算效率，并且保证信息流的连续性。主要使用固定结构的残差块。该残差块能够降低特征图的分辨率，同时保持残差连接，以增强梯度传播的稳定性。在网络的不同阶段，该模块用于执行通道数扩展，并通过步长为2的卷积操作进行降采样。每个残差块包含2个 3×3 卷积层，卷积后紧接批归一化和ReLU激活函数，以确保模型训练的稳定性。当输入和输出通道数不匹配时，采用 1×1 卷积调整通道数，从而保证残差连接的正确性。此外，该模块能够有效缓解深度网络中的梯度消失问题，使得超网在更深层次依然能够保持良好的优化效果。

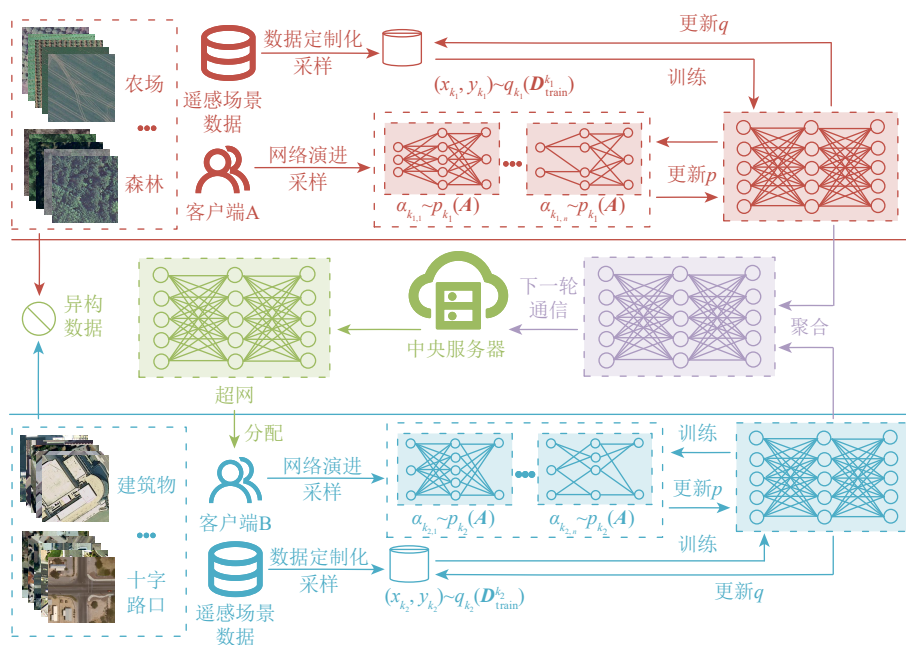


图1 本文提出方法的基本框架

Fig. 1 The framework of the proposed method

本文方法分为超网训练和子网络搜索2个阶段, 不同于集中式神经网络架构搜索 (Liu 等, 2023; Lu 等, 2024), 本文方法在多个客户端并行进行超网训练, 每个客户端在本地进行路径采样和数据采样, 以减少超网梯度方差并提高排名一致性。随后, 通过全聚合策略, 在共享超网基础上进行子网搜索。在联邦学习环境下, 超网训练的核心挑战在于数据的非独立同分布特性、通信约束以及计算资源的限制。由于各客户端数据分布不同, 若直接在所有客户端上进行统一的超网训练, 可能导致模型性能下降, 计算资源消耗升高, 并影响子网的排名一致性。为此, 本文采用了一种基于采样的超网训练策略, 使得每个客户端能够自适应地选择子网进行训练, 以减少梯度方差, 提高训练稳定性, 降低计算成本。

本文首先定义一个包含所有可能搜索架构的超网 N , 并在训练过程中根据路径采样分布 $p_k(\mathbf{A})$ 和数据采样分布 $q_k(\mathbf{D}_k^{\text{min}})$ 进行优化。在每轮训练中, 每个客户端 k 执行以下步骤:

第一步, 根据路径采样分布 $p_k(\mathbf{A})$ 采样子网 α_k , 确保重要子网被频繁采样, 降低超网训练时的梯度方差。

第二步, 从本地数据 $\mathbf{D}_k^{\text{min}}$ 中依据数据采样分布 $q_k(\mathbf{D}_k^{\text{min}})$ 抽取训练样本 $(\mathbf{x}_k, \mathbf{y}_k)$, 保证关键数据被高频采样, 缓解数据分布不均带来的梯度方差过大问题, 同时降低大规模遥感数据集带来的计算成本。

第三步, 计算局部损失 $L(N(\mathbf{x}_k, \alpha_k; \omega_{\alpha_k}), \mathbf{y}_k)$, 并基于局部梯度更新超网参数 ω 。

完成以上训练后, 由于超网在不同客户端上独立训练, 为保证模型收敛性, 本文采用了全局聚合策略, 每轮训练结束后, 服务器端计算所有客户端上传的模型参数加权平均:

$$\omega^{t+1} = \sum_{k=1}^K \frac{n_k}{n} \omega_k^t$$

式中, ω_k^t 为客户端 k 在第 t 轮训练后得到的模型参数。该策略确保了各客户端的贡献被公平考虑, 提高了超网的稳定性。

2.3 路径采样优化

路径采样的核心目标是减少超网训练过程中的梯度方差, 提高不同子网的排名一致性。均匀

采样策略将等概率采样各子网, 但这种方式无法体现不同架构的重要性, 可能导致训练资源浪费并降低子网排名一致性。研究 (Lu 等, 2023) 表明, 最优路径采样分布与梯度范数成正相关。基于这一理论, 本文设计基于梯度范数的路径采样策略, 使重要子网被更频繁地训练, 有效降低梯度方差。

假设在客户端 k 上, α_k 表示当前采样的子网, 其梯度 $\nabla_{\omega} L$ 的范数反映了该子网对超网训练的影响, 因此最优路径采样概率 $p_k^*(\alpha)$ 可定义为

$$p_k^*(\alpha) = \frac{\left\| \nabla_{\omega} L(N(\mathbf{x}_k, \alpha_k; \omega_{\alpha_k}), \mathbf{y}_k) \right\|}{\sum_{\alpha_k \in \mathbf{A}} \left\| \nabla_{\omega} L(N(\mathbf{x}_k, \alpha_k; \omega_{\alpha_k}), \mathbf{y}_k) \right\|}$$

式中, 梯度范数越大, 表明该路径的参数更新方向对损失函数的优化越关键, 对应的子网 α_k 被采样的概率就越大。

随着模型深度的增加, 跳跃连接操作的梯度会越大, 这就导致子网提取结果越加靠近跳跃连接操作, 最终跳跃连接操作占据了大部分的计算节点, 使得结果无法收敛到最优子网。为进一步平衡梯度范数对采样概率的影响, 本文引入归一化指数函数和温度参数 τ , 通过控制温度参数灵活调节模型对高梯度路径的依赖程度, 让搜索过程能在空间中进行充分搜寻将路径采样概率定义为

$$p_k(\alpha_k) = \frac{e^{\left\| \nabla_{\omega} L(N(\mathbf{x}_k, \alpha_k; \omega_{\alpha_k}), \mathbf{y}_k) \right\| / \tau}}{\sum_{\alpha_k \in \mathbf{A}} e^{\left\| \nabla_{\omega} L(N(\mathbf{x}_k, \alpha_k; \omega_{\alpha_k}), \mathbf{y}_k) \right\| / \tau}}$$

式中, 温度参数控制采样分布的平滑程度, 接近0时, 高梯度路径的采样概率被强化, 分布侧重利用已知有效路径; 温度参数越大, 概率分布越平滑, 促进算法对低梯度路径的探索, 避免陷入局部最优。

该策略可以有效平衡采样概率的偏差, 防止个别子网被过度采样。在实际的实验中, 在训练刚开始时设置较低的温度参数, 先快速寻找梯度范数最大的路径, 接着逐步增大温度参数, 让算法开始探索低梯度路径, 提高搜索最优子网的概率。

2.4 数据采样优化

由于联邦学习中不同客户端的数据分布可能存在显著差异, 数据采样的优化对超网训练同样至关重要。均匀采样可能导致部分类别数据未能

充分训练,影响模型泛化能力。研究表明,根据归一化梯度范数对训练数据进行采样有助于减少深度模型训练的梯度方差。基于这一理论,本文设计了基于梯度范数的数据采样策略。设 D_k^{min} 为客户端 k 的本地训练数据集,某个数据样本 $(\mathbf{x}_k, \mathbf{y}_k)$ 的梯度范数反映了其对模型训练的影响力。最优数据采样分布 $q_k^*(\mathbf{x}_k, \mathbf{y}_k)$ 可定义为

$$q_k^*(\mathbf{x}_k, \mathbf{y}_k) \sim \left\| \nabla_{\omega} L \left(N(\mathbf{x}_k, \alpha_k; \omega_{\alpha_k}), \mathbf{y}_k \right) \right\|$$

式中,梯度范数是用于衡量样本对当前子网路径的贡献程度,范数越大,该样本重要性越高。然而,基于批量计算的自动微分机制仅提供平均梯度,无法解耦单个样本的独立梯度。若强制逐样本计算,需对每个输入单独执行前向-反向传播,这会大大提高时间复杂度,对于大规模数据集几乎不可行。因此,可以将最后一层预激活输出视为梯度上界的有效估计,采用近似方法衡量数据重要性:

$$q_k(\mathbf{x}_k, \mathbf{y}_k) = \frac{\Omega \left(\left\| \nabla_{\omega} L \left(N(\mathbf{x}_k, \alpha_k; \omega_{\alpha_k}), \mathbf{y}_k \right) \right\| \right)}{\sum_{(\mathbf{x}_i, \mathbf{y}_i) \in D_k^{\text{min}}} \Omega \left(\left\| \nabla_{\omega} L \left(N(\mathbf{x}_i, \alpha_i; \omega_{\alpha_i}), \mathbf{y}_i \right) \right\| \right)} \approx \frac{\nabla L_k}{\sum_{(\mathbf{x}_i, \mathbf{y}_i) \in D_k^{\text{min}}} \nabla L_k}$$

式中, Ω 指梯度的上界。在联邦遥感场景分类任务中,最后一层预激活输出通常经过 softmax 层。使用交叉熵损失时,可预先推导出的梯度表达式,并在训练过程中计算其值。

2.5 子网络架构提取

在超级网络训练完成后,每个客户端需从中提取个性化子网络。本文采用基于进化神经网络架构 (Yang 等, 2020; Peng 等, 2023) 的子网提取方法,以子网在客户端验证集上的准确率作为适应度度量。在子网编码方面,将每个子网表示为一个整数序列,序列中的每个元素对应可搜索单元中的一条边的操作选择。架构搜索空间中的候选算子操作如表 1 所示。可见本文的搜索空间包含 8 种候选操作,每个搜索单元内有 6 条计算边,因此子网可编码为一个包含 6 个元素的整数序列,每个元素取值范围为 0—8。首先,随机初始化一个子网种群。然后,在每一代进化中,选择适应度高的两个亲本进行交叉和变异,生成子代。计算子代在客户端验证集上的适应度,如果子代

未在种群中出现过,则将其加入种群。这一过程重复进行,直至达到预设的进化代数。最终,选择种群中适应度最高的子网作为客户端的个性化网络。

表 1 架构搜索空间中的候选算子操作列表

Table 1 The list of candidate operator operations in the architecture search space

操作编码	操作名称	描述
0	none	无操作(不选择任何算子)
1	noise	噪声操作
2	max_pool_3x3	3x3 最大池化
3	avg_pool_3x3	3x3 平均池化
4	skip_connect	跳跃连接
5	sep_conv_3x3	3x3 深度可分离卷积
6	sep_conv_5x5	5x5 深度可分离卷积
7	dil_conv_3x3	3x3 膨胀卷积
8	dil_conv_5x5	5x5 膨胀卷积

3 实验设置与结果分析

3.1 实验设置

本文采用的遥感场景分类数据集为 AID (Xia 等, 2017)、NWPU-RESISC45 (Cheng 等, 2017)、PatternNet (Zhou 等, 2018) 和 MEET (Li 等, 2025b)。实验均在 CUDA 12.4 版本的双 NVIDIA GeForce RTX 4090 上进行,全局通信轮数设置为 50。在数据分布方面,由于本文针对实际遥感应用展开研究,因此在更符合现实的非独立同分布数据下进行实验。在方法度量方面,本文采用 Top1 准确率和模型参数数量作为算法对比的度量,同时使用每类的准确率 (Per-class Accuracy) 来衡量算法在不同类别上的泛化性。

3.2 客户端数据分布与数量的参数分析

3.2.1 Dirichlet 分布参数分析

Dirichlet 分布参数对 Top1 准确率和类精确率的影响见图 2。可见,随着 Dirichlet 分布参数的增长,Top1 准确率趋于下降,类准确率却在逐渐上升。这是因为 Dirichlet 分布参数决定了数据分布的均衡程度,数值越小,越不均衡,这就导致参数为 0.1 的时候,数据分布极其不均衡,单个客户端的类别数量最多只有 2 个类,其他类占比会非常少,这就使训练过程变成了一种接近二分类训练

的情况, 所以 Top1 准确率会非常高。反而类准确率很低, 这是因为类准确率衡量的是模型在每个类上的表现, 数据极度不平衡的情况会导致模型只能充分学习到个别类的特征。因此随着 Dirichlet

分布参数的上升, 数据分布趋于均衡, 越来越接近独立同分布的情况, 平均准确率开始上升, 每个客户端的独立模型才能学习到所有类的特征。

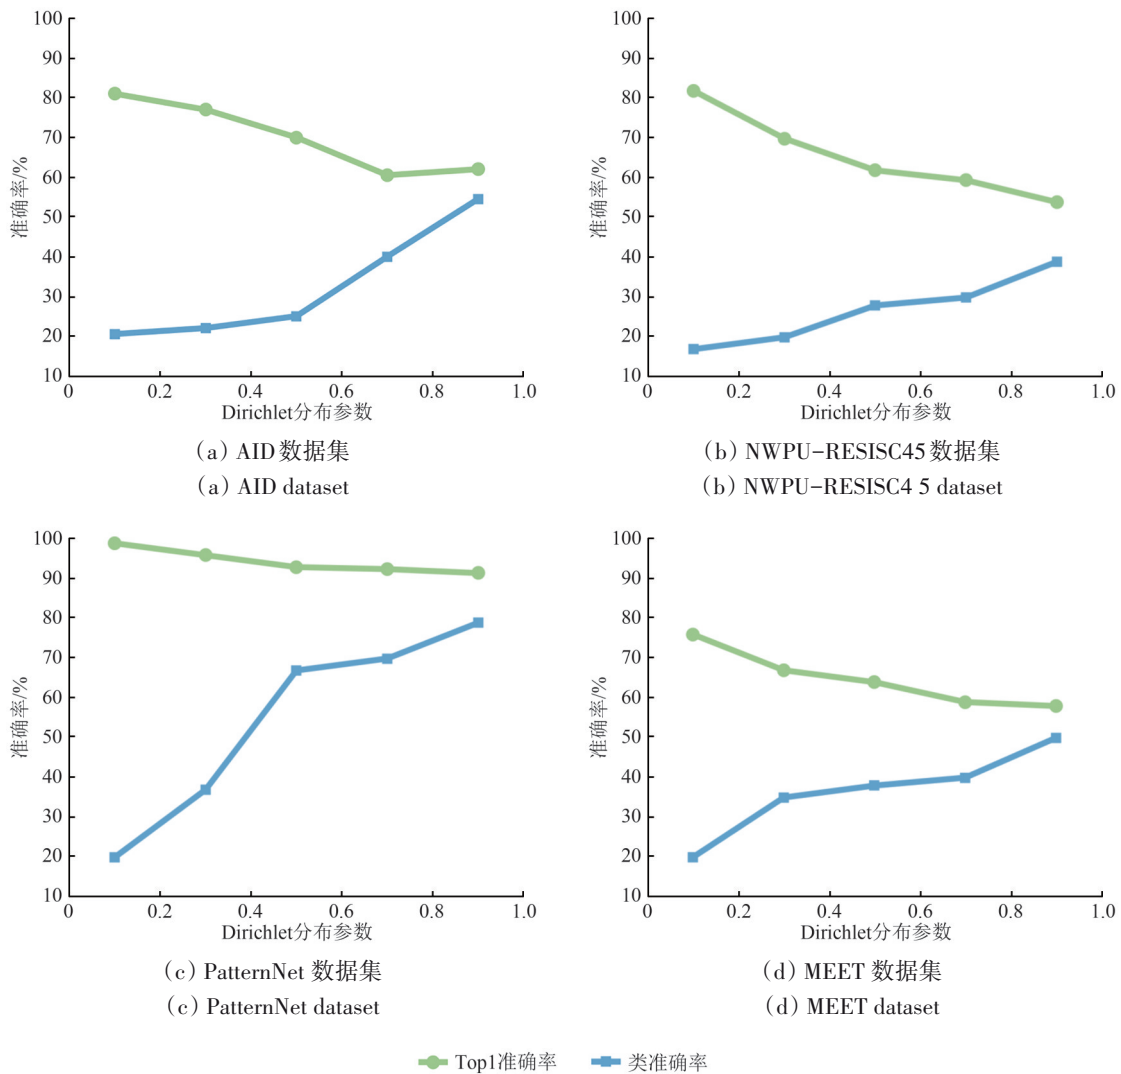


图2 不同数据集在不同Dirichlet分布参数下Top1准确率和类准确率对比

Fig. 2 The Dirichlet distribution parameter experimental analysis results

在4个联邦遥感场景分类数据集上, 随着Dirichlet分布参数从0.1增至0.9, Top1准确率与类准确率呈现出显著的负相关权衡关系。具体而言, 所有数据集的Top1准确率均随Dirichlet分布参数增大而普遍下降, 其中NWPU-RESISC45降幅最为显著, 主要归因于NWPU-RESISC45数据集较高的类内多样性与复杂的场景语义混淆, 而PatternNet凭借更好的特征可分性与清晰的类间界限仍保持最高基准性能。相反, 类准确率则随Dirichlet分布参数增大呈现一致上升趋势。这一现

象表明, 较小的Dirichlet分布参数值倾向于优化模型对多数类或高置信度样本的预测能力, 而较大的Dirichlet分布参数值则通过平滑概率分布有效提升了模型对少数类及难分样本的识别均衡性, 证实了Dirichlet参数调节在平衡整体精度与类别间泛化性能方面的有效性。

3.2.2 客户端数量参数分析

为研究本文提出方法在不同规模联邦环境下的性能, 图3展示了不同客户端数量对方法在3个

数据集上平均准确率的影响。可见随着客户端数量增大,本文提出的方法性能会逐渐下降,并且,相对于数量较少的客户端场景,客户端数量越大,精度下降越明显。导致这个现象的主要原因有两方面:一方面是在实验设置中,本文使用的3个基准数据集根据参与者数量进行了数据划分,这就导致随着参与者数量的上升每个客户端的数量分布更加不均衡,并且每个参与者用于训练的数据量也会下降,影响到了重要路径和重要数据的采样;另一方面,由于参与者之间的本地训练是相互独立的,训练时梯度的方向更加复杂多样,这也就导致参与者越多,服务器需要聚合的参数就越多,需要兼顾的客户端梯度方向也就越多。

3.2.3 双路径采样消融实验

为了验证本文方法的有效性,表2展示了4个基准遥感场景分类数据集的消融实验结果。其中,“基线”指的是在没有使用路径采样和数据采样算法情况下进行的联邦神经架构搜索。实验的结果是所有客户端准确率的平均值AA(Averaged Accuracy),用于体现算法的性能,同时统计了算法计算时间(GPU-Days)和模型浮点运算次数(FLOPs),用于体现算法的效率。由表2,相比于

基线模型,本文的方法在性能、推理效率上都有着明显的提升,路径和数据联合采样能有效提升超级网络训练时的子网一致性,从而提高客户端提取最佳子网的概率。相比于基线需要每个客户端对完整超网进行训练,本文通过路径采样提取重要子网进行训练,大幅降低了计算开销。同时,结合数据采样,确保子网仅在关键数据上优化,不仅提高了训练效率,还有效缓解了如MEET这种大规模遥感数据集带来的计算资源消耗问题。

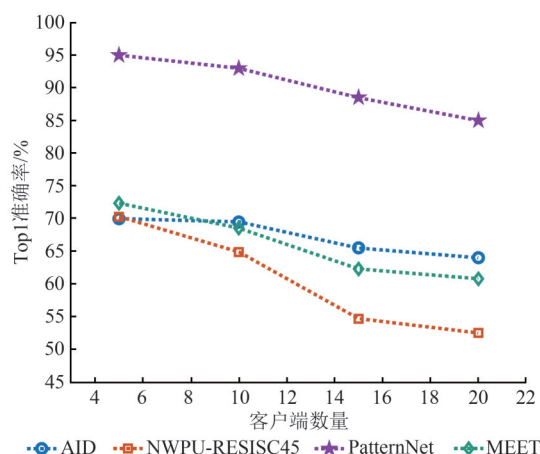


图3 不同客户端数量下不同数据集的Top1准确率
Fig. 3 The experimental results in different numbers of clients

表2 4个基准数据集消融实验结果

Table 2 The ablation experiments on four benchmark datasets

方法	AID			NWPU-RESISC45			PatternNet			MEET		
	AA/%	FLOPs/G	GPU-Days	AA/%	FLOPs/G	GPU-Days	AA/%	FLOPs/G	GPU-Days	AA/%	FLOPs/G	GPU-Days
基线	60.43	1.63	0.6	56.80	1.61	1.5	91.32	1.73	1.5	55.22	1.80	2.4
本文	64.55	0.40	0.3	64.42	0.37	0.4	94.00	0.41	0.4	65.90	0.53	1.1

注: AA代表平均准确率;FLOPs代表模型浮点运算次数;GPU-Days代表算法计算时间。加粗字体表示各列对应指标的最优结果。

3.3 不同网络架构联邦协同对比实验

为了验证本文提出方法有效性,采用以下的方法进行比较,包括人工设计的网络:ResNet-50(He等,2016)、MobileNet-V2(Sandler等,2018);Transformer视觉网络模型:Twins(Chu等,2021);遥感场景分类模型:LiAP(Lu等,2025);网络剪枝策略:Taylor Pruning(Molchanov等,2017)、Network Slimming(Liu等,2017)和联邦遥感场景分类网络轻量化框架HAPF(Hu等,2025)。其中“†”表示该剪枝方法是基于VGG-16架构(Simonyan和Zisserman,2015)进行网络剪枝。值得注意的是,为了保证公平性,所有方法均在相

同的数据分布下进行。

表2—表5给出了在4个数据集上本文提出的方法与不同架构和剪枝方法的Top1准确率和网络参数大小的对比,并给出了不同客户端的详细数据。与人工设计的网络和网络剪枝算法相比,本文的方法在异构数据分布的情况下更加适应不同场景的数据集,并且不同客户端所提取的子网在参数数量上有着显著优势。

具体而言,人工设计的卷积神经网络,如ResNet50等,在AID数据集和NWPU-RESISC45数据集的表现都不太理想。这是因为这种固定的卷积神经架构只能适应部分场景,无法在数据分布

不均的情况下, 满足所有客户端的需求。相比较而言, 基于Transformer架构的Twins, 无论在哪个数据集的表现都不太理想, 尤其是在类间差异大的NWPU-RESISC45和MEET数据集上。这是因为

数据异构性容易导致模型无法朝着正确方向收敛, 且各客户端的Transformer架构往往需要依赖大规模的预训练特征, 而在没有任何先验知识的情况下模型容易欠拟合。

表3 AID数据集不同客户端Top1准确率和模型参数量对比实验结果

Table 3 Comparison of the Top1 accuracy and model parameters of different clients in the AID dataset

方法	指标	客户端1	客户端2	客户端3	客户端4	客户端5	客户端6	客户端7	客户端8	客户端9	客户端10
ResNet50		51.56	52.43	66.96	51.95	61.25	47.50	61.53	50.00	58.98	57.42
	Params./M	23.57	23.57	23.57	23.57	23.57	23.57	23.57	23.57	23.57	23.57
MobileNetV2	AA/%	47.50	57.29	62.05	53.51	60.31	48.75	63.70	58.92	62.50	62.89
	Params./M	2.26	2.26	2.26	2.26	2.26	2.26	2.26	2.26	2.26	2.26
Twins	AA/%	48.12	49.30	56.69	52.73	56.25	41.87	56.73	45.98	54.68	54.69
	Params./M	22.52	22.52	22.52	22.52	22.52	22.52	22.52	22.52	22.52	22.52
LiAP	AA/%	66.68	65.80	73.18	68.61	65.44	62.32	64.38	71.10	69.03	67.41
	Params./M	3.46	3.46	3.46	3.46	3.46	3.46	3.46	3.46	3.46	3.46
Taylor Pruning [†]	AA/%	66.56	65.69	73.03	68.51	65.31	62.18	64.27	70.98	68.90	67.31
	Params./M	3.52	3.52	3.52	3.52	3.52	3.52	3.52	3.52	3.52	3.52
Network Slimming [†]	AA/%	63.75	63.75	69.91	73.82	63.75	65.31	63.31	72.76	67.34	66.56
	Params./M	3.15	3.34	3.36	3.40	3.41	3.43	3.37	3.41	3.40	3.36
HAPF [†]	AA/%	64.23	64.32	70.33	74.37	64.26	65.75	63.90	73.22	67.87	66.97
	Params./M	2.92	3.13	3.11	3.20	3.17	3.21	3.12	3.20	3.17	3.12
本文	AA/%	73.43	70.48	67.85	75.39	70.00	65.62	73.79	72.76	71.87	69.92
	Params./M	0.26	0.23	0.11	0.26	0.24	0.17	0.28	0.21	0.26	0.30

注: AA代表平均准确率; Params.代表模型参数量。加粗字体表示各列(客户端)在模型准确率和参数量指标的最优结果。

表4 NWPU-RESISC45数据集不同客户端Top1准确率和模型参数量对比实验结果

Table 4 Comparison of the Top1 accuracy and model parameters of different clients in the NWPU-RESISC45 dataset

方法	指标	客户端1	客户端2	客户端3	客户端4	客户端5	客户端6	客户端7	客户端8	客户端9	客户端10
ResNet50	AA/%	48.75	64.37	48.21	53.12	48.63	48.43	46.69	59.91	44.16	46.70
	Params./M	23.57	23.57	23.57	23.57	23.57	23.57	23.57	23.57	23.57	23.57
MobileNetV2	AA/%	47.23	61.97	47.99	54.95	50.97	50.20	53.49	54.48	46.66	46.52
	Params./M	2.26	2.26	2.26	2.26	2.26	2.26	2.26	2.26	2.26	2.26
Twins	AA/%	39.91	52.39	34.15	41.05	35.54	32.29	38.32	45.24	31.25	34.20
	Params./M	22.52	22.52	22.52	22.52	22.52	22.52	22.52	22.52	22.52	22.52
LiAP	AA/%	55.91	73.35	60.83	63.20	57.15	60.03	60.73	56.86	56.82	59.42
	Params./M	3.25	3.25	3.25	3.25	3.25	3.25	3.25	3.25	3.25	3.25
Taylor Pruning [†]	AA/%	55.08	72.60	60.15	62.28	56.54	59.06	60.01	55.97	56.04	58.78
	Params./M	3.53	3.53	3.53	3.53	3.53	3.53	3.53	3.53	3.53	3.53
Network Slimming [†]	AA/%	58.48	72.50	61.27	65.19	57.03	66.25	64.61	67.39	59.27	56.07
	Params./M	3.45	3.41	3.38	3.40	3.44	3.38	3.41	3.42	3.41	3.39
HAPF [†]	AA/%	58.60	72.43	61.45	65.04	57.07	66.06	64.70	67.36	59.43	55.96
	Params./M	2.83	2.73	2.81	2.76	2.85	2.73	2.81	2.75	2.85	2.76
本文	AA/%	64.46	77.81	62.61	65.94	64.16	62.60	59.37	67.79	60.10	59.37
	Params./M	0.31	0.15	0.31	0.24	0.15	0.27	0.17	0.24	0.32	0.23

注: AA代表平均准确率; Params.代表模型参数量。加粗字体表示各列(客户端)在模型准确率和参数量指标的最优结果。

表5 PatternNet数据集不同客户端Top1准确率和模型参数量对比实验结果

Table 5 Comparison of the Top1 accuracy and model parameters of different clients in the PatternNet dataset

方法	指标	客户端1	客户端2	客户端3	客户端4	客户端5	客户端6	客户端7	客户端8	客户端9	客户端10
ResNet50	AA/%	90.99	90.04	90.76	88.43	90.00	90.72	91.25	89.13	89.87	89.41
	Params./M	23.57	23.57	23.57	23.57M	23.57	23.57	23.57	23.57	23.57	23.57
MobileNetV2	AA/%	89.98	92.24	91.90	89.79	90.52	91.30	91.16	89.40	90.73	92.70
	Params./M	2.26	2.26	2.26	2.26	2.26	2.26	2.26	2.26	2.26	2.26
Twins	AA/%	85.66	84.60	86.50	81.97	84.89	85.15	84.01	79.75	77.47	81.25
	Params./M	22.52	22.52	22.52	22.52	22.52	22.52	22.52	22.52	22.52	22.52
LiAP	AA/%	92.55	91.15	89.71	91.38	93.01	92.36	92.41	89.49	91.75	87.54
	Params./M	3.20	3.20	3.20	3.20	3.20	3.20	3.20	3.20	3.20	3.20
Taylor Pruning†	AA/%	92.37	90.27	89.48	91.45	93.87	92.57	92.32	85.73	91.59	85.59
	Params./M	3.53	3.53	3.53	3.53	3.53	3.53	3.53	3.53	3.53	3.53
Network Slimming†	AA/%	94.03	93.71	94.88	93.93	93.31	92.28	94.35	93.10	93.76	93.18
	Params./M	3.38	3.42	3.39	3.35	3.37	3.38	3.40	3.46	3.46	3.46
HAPF†	AA/%	93.79	92.45	92.35	92.08	93.96	92.12	93.03	88.97	92.95	89.42
	Params./M	2.75	2.87	2.70	2.77	2.86	2.71	2.80	2.93	2.81	2.89
本文	AA/%	94.02	93.98	94.74	93.95	93.33	93.06	94.37	93.75	94.39	94.44
	Params.	0.27M	0.15M	0.26M	0.24M	0.16M	0.29M	0.17M	0.15M	0.21M	0.29M

注: AA代表平均准确率;Params.代表模型参数量。加粗字体表示各列(客户端)在模型准确率和参数量指标的最优结果。

相比之下,本文提出的方法能够在大规模体系架构空间中自动搜索最优或次优网络体系架构,每个客户端可以获取适合本地数据特征分布的网络,相比于网络剪枝这种基于固定模型进行后续处理的算法,能够实现全局最优资源的利用。

表6 MEET数据集不同客户端Top1准确率(%)和模型参数量(M)对比实验结果

Table 6 Comparison of the Top1 accuracy (%) and model parameters (M) of different clients in the MEET dataset

方法	指标	客户端1	客户端2	客户端3	客户端4	客户端5	客户端6	客户端7	客户端8	客户端9	客户端10
ResNet50	AA/%	65.03	55.68	70.74	57.94	64.32	53.17	65.81	61.63	57.66	54.87
	Params./M	23.57	23.57	23.57	23.57	23.57	23.57	23.57	23.57	23.57	23.57
MobileNetV2	AA/%	66.14	53.69	69.24	59.16	62.59	55.01	64.16	63.02	56.39	56.45
	Params./M	2.26	2.26	2.26	2.26	2.26	2.26	2.26	2.26	2.26	2.26
Twins	AA/%	62.48	50.26	65.63	55.73	59.39	51.86	60.19	59.40	52.88	53.22
	Params./M	22.52	22.52	22.52	22.52	22.52	22.52	22.52	22.52	22.52	22.52
LiAP	AA/%	70.14	60.25	75.93	62.73	67.49	58.28	70.33	65.83	63.15	58.69
	Params./M	4.58	4.58	4.58	4.58	4.58	4.58	4.58	4.58	4.58	4.58
Taylor Pruning†	AA/%	71.87	58.73	76.42	61.21	66.01	57.12	69.03	64.31	64.80	57.45
	Params./M	4.75	4.75	4.75	4.75	4.75	4.75	4.75	4.75	4.75	4.75
Network Slimming†	AA/%	71.54	57.26	78.87	59.45	67.89	55.68	68.35	65.79	66.45	55.87
	Params./M	4.60	4.65	4.55	4.61	4.57	4.54	4.66	4.60	4.63	4.58
HAPF†	AA/%	72.69	58.46	79.20	57.96	67.82	56.18	66.20	66.78	66.70	54.86
	Params./M	4.17	3.93	4.15	4.02	4.28	4.08	3.97	4.19	4.23	3.90
本文	AA/%	75.24	62.83	82.35	62.42	70.67	59.95	72.17	70.31	69.54	60.01
	Params.	0.52M	0.49M	0.58M	0.52M	0.46M	0.55M	0.60M	0.51M	0.45M	0.53M

注: AA代表平均准确率;Params.代表模型参数量。加粗字体表示各列(客户端)在模型准确率和参数量指标的最优结果。

4 结 论

为解决联邦遥感场景分类中固定网络架构难以适配异构客户端设备问题,本文提出一种基于路径与数据协同采样的联邦神经架构搜索方法,并在4个基准异构遥感场景分类数据集上进行实验验证。主要结论如下:(1)通过梯度范数引导的路径采样与数据采样双维度协同机制,显著降低了超网训练的计算与通信开销,提升了子网络性能的一致性;(2)在子网部署阶段利用进化算法搜索最优个性化子网,解决了非独立同分布数据导致的模型泛化性不足问题,实现了隐私保护下的轻量高效个性化模型构建;(3)在客户端资源受限条件下,该方法模型参数量远低于主流剪枝方法与固定架构模型,且分类准确率显著提升,有效提升了联邦遥感系统的部署可行性与整体性能。

当前工作的局限性在于客户端数量大幅增加时性能下降,且进化算法的搜索效率需进一步优化。未来计划探索轻量化神经架构搜索与增量式联邦学习的融合机制,以支持动态客户端环境;同时研究跨客户端架构知识迁移,提升大规模客户端下的模型鲁棒性。

参考文献(References)

Ben Youssef B, Alhmid L, Bazi Y and Zuair M. 2024. Federated learning approach for remote sensing scene classification. *Remote Sensing*, 16(12): 2194 [DOI: 10.3390/rs16122194]

Büyüktaş B, Sumbul G and Demir B. 2024. Federated learning across decentralized and unshared archives for remote sensing image classification: a review. *IEEE Geoscience and Remote Sensing Magazine*, 12(3): 64-80 [DOI: 10.1109/MGRS.2024.3415391]

Chen Z H, Qiu G H, Li P, Zhu L, Yang X K and Sheng B. 2023. MNG-NAS: distilling adaptive combination of multiple searched networks for one-shot neural architecture search. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 45(11): 13489-13508 [DOI: 10.1109/TPAMI.2023.3293885]

Cheng G, Han J W and Lu X Q. 2017. Remote sensing image scene classification: benchmark and state of the art. *Proceedings of the IEEE*, 105(10): 1865-1883 [DOI: 10.1109/JPROC.2017.2675998]

Cheng G, Xie X X, Han J W, Guo L and Xia G S. 2020. Remote sensing image scene classification meets deep learning: challenges, methods, benchmarks, and opportunities. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 13: 3735-3756 [DOI: 10.1109/JSTARS.2020.3005403]

Chu X X, Tian Z, Wang Y Q, Zhang B, Ren H B, Wei X L, Xia H X

and Shen C H. 2021. Twins: revisiting the design of spatial attention in vision transformers//*Proceedings of the Annual Conference on Neural Information Processing Systems*. Virtual: [s.n.]: 9355-9366

He K M, Zhang X Y, Ren S Q and Sun J. 2016. Deep residual learning for image recognition//*Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Las Vegas: IEEE: 770-778 [DOI: 10.1109/CVPR.2016.90]

Hu Z P, Gong M G, Dong Z W, Lu Y H, Li J Z and Zhao Y. 2025. Heterogeneity-aware pruning framework for personalized federated learning in remote sensing scene classification. *Knowledge-Based Systems*, 311: 113007 [DOI: 10.1016/j.knsys.2025.113007]

Li T, Sahu A K, Talwalkar A and Smith V. 2020. Federated learning: challenges, methods, and future directions. *IEEE Signal Processing Magazine*, 37(3): 50-60 [DOI: 10.1109/MSP.2020.2975749]

Li J Z, Gong M G, Liu Z T, Wang S F, Zhang Y R, Zhou Y and Gao Y. 2024. Toward multiparty personalized collaborative learning in remote sensing. *IEEE Transactions on Geoscience and Remote Sensing*, 62: 4503616 [DOI: 10.1109/TGRS.2024.3370584]

Li J Z, Wang S F, Yang R, Gong M G, Hu Z P, Zhang N, Sheng K and Zhou Y. 2025a. Toward federated customized neural architecture search for remote sensing scene classification. *IEEE Transactions on Geoscience and Remote Sensing*, 63: 4502012 [DOI: 10.1109/TGRS.2025.3537085]

Li Y S, Wu Y N, Cheng G, Tao C, Dang B, Wang Y, Zhang J H, Zhang C G, Liu Y T, Tang X, Ma J Y and Zhang Y J. 2025b. MEET: a million-scale dataset for fine-grained geospatial scene classification with zoom-free remote sensing imagery. *IEEE/CAA Journal of Automatica Sinica*, 12(5): 1004-1023 [DOI: 10.1109/JAS.2025.125324]

Liu J C, Yan J M, Xu H L, Wang Z Y, Huang J Y and Xu Y. 2024. Finch: enhancing federated learning with hierarchical neural architecture search. *IEEE Transactions on Mobile Computing*, 23(5): 6012-6026 [DOI: 10.1109/TMC.2023.3315451]

Liu Y Q, Sun Y N, Xue B, Zhang M J, Yen G G and Tan K C. 2023. A survey on evolutionary neural architecture search. *IEEE Transactions on Neural Networks and Learning Systems*, 34(2): 550-570 [DOI: 10.1109/TNNLS.2021.3100554]

Liu Z, Li J G, Shen Z Q, Huang G, Yan S M and Zhang C S. 2017. Learning efficient convolutional networks through network slimming//*Proceedings of the 2017 IEEE International Conference on Computer Vision (ICCV)*. Venice: IEEE: 2755-2763 [DOI: 10.1109/ICCV.2017.298]

Lu S, Hu Y, Yang L X, Sun Z H, Mei J L, Tan J C and Song C R. 2023. PA and DA: jointly sampling path and data for consistent NAS//*Proceedings of the 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. Vancouver: IEEE: 11940-11949 [DOI: 10.1109/CVPR52729.2023.01149]

Lu Y H, Hu Z P, Zhao W, Guan Z Y, Gong M G and Zhang M Y. 2025. Layer-interaction adaptive pruning for remote sensing scene classification. *IEEE Transactions on Geoscience and Remote Sensing*, 63: 5624712 [DOI: 10.1109/TGRS.2025.3570653]

- Lu Z C, Cheng R, Jin Y C, Tan K C and Deb K. 2024. Neural architecture search as multiobjective optimization benchmarks: problem formulation and performance assessment. *IEEE Transactions on Evolutionary Computation*, 28(2): 323-337 [DOI: 10.1109/TEVC.2022.3233364]
- Molchanov P, Tyree S, Karras T, Aila T and Kautz J. 2017. Pruning convolutional neural networks for resource efficient inference. arXiv:1611.06440 [DOI: 10.48550/arXiv.1611.06440]
- Peng Y M, Song A, Ciesielski V, Fayek H M and Chang X J. 2023. PRE-NAS: evolutionary neural architecture search with predictor. *IEEE Transactions on Evolutionary Computation*, 27(1): 26-36 [DOI: 10.1109/TEVC.2022.3227562]
- Qian X L, Li J, Cheng G, Yao X W, Zhao S N, Chen Y B and Jiang L Y. 2018. Evaluation of the effect of feature extraction strategy on the performance of high-resolution remote sensing image scene classification. *Journal of Remote Sensing*, 22(5): 758-776 (钱晓亮, 李佳, 程堪, 姚西文, 赵素娜, 陈宜滨, 姜利英. 2018. 特征提取策略对高分辨率遥感图像场景分类性能影响的评估. *遥感学报*, 22(5): 758-776) [DOI: 10.11834/jrs.20188015]
- Sandler M, Howard A, Zhu M L, Zhmoginov A and Chen L C. 2018. MobileNetV2: inverted residuals and linear bottlenecks//Proceedings of the 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Salt Lake City: IEEE: 4510-4520 [DOI: 10.1109/CVPR.2018.00474]
- Simonyan K and Zisserman A. 2015. Very deep convolutional networks for large-scale image recognition. arXiv:1409.1556 [DOI: 10.48550/arXiv.1409.1556]
- Sun X, Meng Y, Diao W H, Huang L J, Zhang X, Luo J C, Gao L R, Wang P J, Yan Z Y, Gao L J, Dong W, Feng Y C, Li J H and Fu K. 2022. The review of AI-based intelligent remote sensing capabilities. *Journal of Image and Graphics*, 27(6): 1799-1822 (孙显, 孟瑜, 刁文辉, 黄丽佳, 张新, 骆剑承, 高连如, 王佩瑾, 闫志远, 郝丽静, 董文, 冯瑛超, 李霖豪, 付琨. 2022. 智能遥感: AI赋能遥感技术. *中国图象图形学报*, 27(6): 1799-1822) [DOI: 10.11834/jig.220161]
- Xia G S, Hu J W, Hu F, Shi B G, Bai X, Zhong Y F, Zhang L P and Lu X Q. 2017. AID: a benchmark data set for performance evaluation of aerial scene classification. *IEEE Transactions on Geoscience and Remote Sensing*, 55(7): 3965-3981 [DOI: 10.1109/TGRS.2017.2685945]
- Yang Q. 2019. AI and data privacy protection: the way to federated learning. *Journal of Information Security Research*, 5(11): 961-965 (杨强. 2019. AI与数据隐私保护: 联邦学习的破解之道. *信息安全研究*, 5(11): 961-965) [DOI: 10.3969/j.issn.2096-1057.2019.11.003]
- Yang Z H, Wang Y H, Chen X H, Shi B X, Xu C, Xu C J, Tian Q and Xu C. 2020. CARS: continuous evolution for efficient neural architecture search//Proceedings of the 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle: IEEE: 1826-1835 [DOI: 10.1109/CVPR42600.2020.00190]
- Yao Y Q, Cheng G, Xie X X and Han J W. 2021. Optical remote sensing image object detection based on multi-resolution feature fusion. *National Remote Sensing Bulletin*, 25(5): 1124-1137 (姚艳清, 程堪, 谢星星, 韩军伟. 2021. 多分辨率特征融合的光学遥感图像目标检测. *遥感学报*, 25(5): 1124-1137) [DOI: 10.11834/jrs.20210505]
- Wang S F, Li J Z, Liu Z T, Gong M G, Zhang Y R, Zhao Y, Deng B Y and Zhou Y. 2024. Personalized multiparty few-shot learning for remote sensing scene classification. *IEEE Transactions on Geoscience and Remote Sensing*, 62: 4506115 [DOI: 10.1109/TGRS.2024.3386978]
- Zhang C H, Yuan X M, Zhang Q Y, Zhu G X, Cheng L and Zhang N. 2022. Toward tailored models on private IoT devices: federated direct neural architecture search. *IEEE Internet of Things Journal*, 9(18): 17309-17322 [DOI: 10.1109/JIOT.2022.3154605]
- Zhang M, Li H Q, Pan S R, Chang X J, Zhou C, Ge Z Y and Su S. 2021. One-shot neural architecture search: maximising diversity to overcome catastrophic forgetting. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 43(9): 2921-2935 [DOI: 10.1109/TPAMI.2020.3035351]
- Zhou W X, Newsam S, Li C M and Shao Z F. 2018. PatternNet: a benchmark dataset for performance evaluation of remote sensing image retrieval. *ISPRS Journal of Photogrammetry and Remote Sensing*, 145: 197-209 [DOI: 10.1016/j.isprsjprs.2018.01.004]

Federated neural architecture autonomous evolution for collaborative remote sensing scene classification

LI Jianzhao¹, WANG Shanfeng², YANG Rui², TANG Zedong¹, ZHOU Yu³, GONG Maoguo^{3,4}

1. Guangzhou Institute of Technology, Xidian University, Guangzhou, 510555, China;

2. School of Cyber Engineering, Xidian University, Xi'an 710071, China;

3. School of Electronic Engineering, Xidian University, Xi'an 710071, China;

4. College of Artificial Intelligence, Inner Mongolia Normal University, Hohhot 010028, China

Abstract: Existing federated remote sensing scene classification methods generally assume a fixed client network architecture, disregarding the significant heterogeneity in computing power, storage, and energy supply among devices such as satellites and drones.

These limitations make deploying models on resource-constrained terminals difficult, restricting the practical efficiency of federated systems. Therefore, a novel federated remote sensing paradigm that is capable of dynamically adapting to the heterogeneity of client data and computational resources must be urgently developed. While safeguarding the data privacy of all parties, this paradigm should collaboratively explore optimal network architectures that are lighter, more computationally efficient, and tailored to the specific characteristics of each client's local data. To address this bottleneck, this study proposes a federated collaborative framework with the autonomous evolution of neural network architectures. It proposes a neural architecture search mechanism based on path and data collaborative sampling to achieve lightweight, efficient, and personalized model construction that adapts to local data characteristics. During the collaborative training phase, each client dynamically screens key subnet architectures through gradient norm-guided path sampling and focuses on high-value samples through data sampling based on gradient upper bounds, significantly reducing supernet training and communication overhead. In the multiparty deployment phase, evolutionary algorithms are used to search for and validate the personalized subnet with the optimal verification accuracy on the basis of local data. The proposed framework's foundational breakthrough lies in its integrated approach wherein gradient norm-guided path sampling dynamically identifies and prioritizes architecturally critical subnets during federated training. Simultaneously, gradient-capped data sampling concentrates computational resources on samples with significant effect on training outcomes. These mechanisms collectively form a synergistic strategy that substantially reduces gradient variance and training overhead across the hypernetwork while respecting client resource constraints. Following this collaborative hypernetwork development, each client autonomously executes evolutionary optimization, extracting customized subnetworks that are precisely tailored to local data distributions through adaptation-driven architecture exploration. By unifying adaptive sampling during training with evolutionary personalization while on deployment, the framework achieves unprecedented efficiency in generating lightweight but high-performance models. These models are optimized for diverse edge devices and their unique remote sensing environments while remaining within strict privacy-preserving federated parameters. Experiments on four benchmark heterogeneous remote sensing classification datasets, namely, AID, NWPU-RESISC45, PatternNet, and MEET, demonstrate that this method significantly outperforms fixed architectures and mainstream pruning methods under nonindependent and identically distributed conditions. It can evolve lightweight, high-performance, and dedicated network architectures for heterogeneous clients while protecting data privacy, effectively enhancing the deployment feasibility and overall performance of federated remote sensing systems. Ablation studies have confirmed that the integrated path-data sampling strategy is pivotal to these gains, reducing gradient variance and improving subnet consistency. This work resolves key bottlenecks in federated remote sensing systems by enabling resource-constrained clients to evolve specialized architectures autonomously. The integration of gradient-guided path sampling and data sampling optimizes training efficiency, while evolutionary optimization facilitates personalized subnet deployment. The proposed framework demonstrably enhances deployment feasibility and overall system performance without compromising data privacy, establishing an effective solution for heterogeneous federated learning in remote sensing scene classification.

Key words: federated learning, remote sensing scene classification, neural architecture search, evolutionary computing, collaborative learning and optimization

Supported by National Natural Science Foundation of China (No. 62506283, 62476210); Postdoctoral Fellowship Program of CPSF (No. GZC20250166); Science and Technology Breakthrough project of Inner Mongolia Autonomous Region (No. 2025KJTW0026)