

基于动态剪枝的跨域小样本图像生成方法研究

李世亮^{1,2}, 方强², 王屹华¹, 施逸飞², 王卓¹, 李泽玉¹, 谢云飞¹, 王佳¹

(1. 西北机电工程研究所, 陕西 咸阳 712099;
2. 国防科技大学智能科学学院, 湖南 长沙 410073)

摘 要: 小样本图像生成在医学成像、艺术创作等领域具有重要的应用价值。近年来, 该任务取得了诸多研究成果, 主流方法通常依赖将大规模源域数据集上预训练的生成模型迁移至目标域, 以缓解目标数据稀缺带来的训练困难。然而, 当源域与目标域之间存在显著语义差异时, 直接迁移往往会引入不兼容的源域特征, 从而引发生成图像真实性降低与风格一致性减弱等问题。现有方法虽通过静态剪枝(如固定阈值裁剪滤波器)去除冗余特征, 但仍难以适应深度网络各层特征表达的动态演化规律, 且易造成浅层通用特征被误删、深层冗余特征残留等问题, 从而影响模型的迁移效果与生成质量。为此, 提出了一种基于滤波器重要性估计的动态剪枝方法。首先, 在训练过程中持续跟踪各层滤波器的 Fisher 信息变化, 衡量其对图像生成质量的重要性程度。然后, 结合 Fisher 信息构建了一种基于累积重要性权重的自适应剪枝机制, 能够动态确定不同层级的剪枝比例, 从而更精准地剔除冗余或不兼容特征的滤波器, 保留通用的结构语义信息。实验在多个具有代表性的小样本目标域上进行, 结果表明, 该方法在生成图像质量指标(FID)和多样性指标(Intra-LPIPS)上显著优于现有方法。其中, 在与源域语义相差较大的目标域中该方法 FID 优于现有最优方法, 验证了其在跨域小样本图像生成任务中的稳定性与优越性。

关 键 词: 小样本图像生成; 跨域迁移; 动态剪枝; Fisher 信息; 生成对抗网络

中图分类号: TP 391.4; TP 18

DOI: 10.11996/JGj.2095-302X.2026010131

文献标识码: A

文章编号: 2095-302X(2026)01-0131-12

A dynamic pruning approach for cross-domain few-shot image generation

LI Shiliang^{1,2}, FANG Qiang², WANG Yihua¹, SHI Yifei², WANG Zhuo¹, LI Zeyu¹, XIE Yunfei¹, WANG Jia¹

(1. Northwest Institute of Mechanical and Electrical Engineering, Xianyang Shaanxi 712099, China;

2. College of Intelligent Science and Technology, National University of Defense Technology, Changsha Hunan 410073, China)

Abstract: Few-shot image generation has important application value in fields such as medical imaging and artistic creation. In recent years, significant research progress has been made in this task, with mainstream approaches typically relying on transferring generative models pretrained on large-scale source domain datasets to target domains to mitigate data-scarcity challenges. However, when substantial semantic gaps exist between source and target domains, direct transfer often introduced incompatible source-specific features, degrading image realism and style consistency. Although existing methods have removed redundant features via static pruning strategies, such as fixed-threshold filter pruning, they struggle to adapt to the dynamic evolution of features across different layers of deep networks, often resulting in the mistaken removal of general low-level features while retaining redundant high-level ones, thereby affecting the adaptation performance and generation quality of the model. To address this, a dynamic pruning method based on filter-importance estimation was proposed. Specifically, the method continuously tracked the changes in Fisher information of each layer's filters during training to evaluate their importance for image generation

收稿日期: 2025-04-30; 定稿日期: 2025-07-21; 通信作者: 方强, E-mail: qiangfang@nudt.edu.cn

Received: 30 April, 2025; Finalized: 21 July, 2025; Corresponding author: FANG Qiang, E-mail: qiangfang@nudt.edu.cn

基金项目: 国家自然科学基金(61703418); 湖南省自然科学基金(2023JJ20051); 湖南省科技创新计划(2023RC3011)

Foundation items: National Natural Science Foundation of China (61703418); the Natural Science Foundation of Hunan Province (2023JJ20051); The Science and Technology Innovation Program of Hunan Province (2023RC3011)

quality. Based on the Fisher information, a cumulative importance weight-based adaptive pruning mechanism was constructed to dynamically determine the pruning ratio for each layer, enabling more precise removal of redundant or incompatible filters while preserving general structural semantic information. Experiments were conducted on several representative few-shot target domains, and results showed that the proposed method significantly outperformed existing approaches in terms of image quality (Frechet Inception Distance, FID) and image diversity (Intra-domain Learned Perceptual Image Patch Similarity, Intra-LPIPS). In target domains exhibiting significant semantic differences from the source domain, the proposed method achieved superior FID scores compared with the current state-of-the-art methods, demonstrating its stability and superiority for cross-domain few-shot image generation tasks.

Keywords: few-shot image generation; transfer learning; dynamic pruning; Fisher information; generative adversarial networks

近年来,随着深度学习技术的快速发展,图像生成任务取得了显著进展。在计算机视觉领域,生成对抗网络^[1](Generative Adversarial Networks, GAN)作为主流方法,被广泛应用于图像生成^[2-4]、风格迁移^[5-7]和数据增强^[8-9]等任务。然而,GAN等深度生成模型^[10]通常依赖大规模数据集学习目标分布^[11-13],因此在小样本场景^[14-15]下,生成图像的质量和多样性往往难以保证^[16]。

小样本图像生成(Few-Shot Image Generation, FSIG)旨在解决有限数据条件下的图像生成问题,即在仅有少量目标域样本(例如 10 个样本)的情况下,生成具有真实感和多样性的图像。该任务在诸多实际应用中具有重要价值,如医学影像分析^[17]、远程感知、虚拟现实等。然而,由于目标数据不足,直接训练生成模型往往会导致模型过拟合,并降低生成图像的质量。因此,近年来研究人员提出了多种迁移学习^[18]和知识保留策略^[19],以提高 FSIG 任务的性能。

在 FSIG 任务中,迁移学习^[20-21]是一种关键技术。通过利用在大规模源数据集上预训练的 GAN 模型,并在小样本目标域上进行适配,可以有效缓解数据稀缺问题,提高生成质量。尽管迁移学习在一定程度上能够提升 FSIG 任务的效果,但现有方法仍面临诸多挑战,如不兼容特征迁移^[22]、跨域分布适配难^[23]以及生成多样性受限等问题。因此,如何有效迁移源域知识、去除不兼容特征,并提高目标域图像生成质量,仍是当前 FSIG 研究的核心问题^[19]。

本文围绕 FSIG 任务展开研究,并针对现有方法存在的兼容特征迁移问题,基于文献^[22]去除不兼容知识(Removing in-Compatible Knowledge, RICK)方法提出了一种基于动态比例剪枝的方法,以提高跨域 FSIG 的质量和稳定性。

如图 1 所示,本文通过分析 RICK 方法在训练过程中各层滤波器 Fisher 信息的重要性变化,揭示了其固有缺陷。通过实验观察到,在不同训练阶段,浅层与深层滤波器的 Fisher 信息分布呈现显著差异:训练初期,浅层滤波器主要贡献通用纹理特征^[24](浅层 Fisher 信息占比高),深层滤波器在后期逐步捕获目标域特有语义(深层 Fisher 信息迅速增高),在训练轮数 500~2 000 次迭代的过程中:深层滤波器对应的 Fisher 信息持续大幅上升;说明深层卷积核越来越关键,捕捉到了与生成目标密切相关的高语义特征。浅层滤波器在不同轮次的 Fisher 信息整体较低,变化也不大,表明其主要负责通用纹理、边缘等底层特征提取,这部分在迁移过程中需求稳定、变化少。中层滤波器的 Fisher 信息处于中等水平,随着训练略有上升,表明其作用介于浅层通用特征与深层语义特征之间,逐步承担更多“转译”任务。因此,若采用固定剪枝比例,无法充分考虑不同层级重要性的动态演化,这会导致浅层通用特征在初期被过度剪除,而深层关键语义通道在后期保留不足,进而影响模型生成效果的稳定性与目标适应能力。

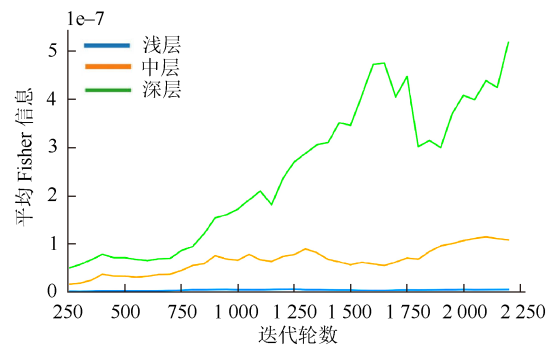


图 1 RICK 不同深度卷积层的 Fisher 信息变化趋势
Fig. 1 Fisher information variation across different-depth convolutional layers in RICK

如图 2 所示, 由于 RICK 方法采用固定剪枝比例, 会使得模型在每轮迭代中强制保持剪枝数量总和不变, 难以适应各层重要性的动态变化。图中可见, 当某层(如深层)剪枝为零时, 浅层和中层的剪枝量明显上升, 反映出其缺乏灵活性。此外, 浅层始终维持较高的剪枝量, 易误删通用特征; 对比图 1, 深层网络在训练后期重要性较高, 而 RICK 则在训练后期仍执行剪枝操作, 这会破坏模型语义表达能力。这些现象进一步暴露出固定剪枝比例在复杂特征表达过程中缺乏灵活性和判别能力, 凸显出构建自适应剪枝机制的必要性。针对此问题, 本文提出了基于重要性权重的动态剪枝方法, 自适应调整剪枝比例, 实现跨域图像生成的不兼容特征有效剔除。




图 2 RICK 在生成器卷积层不同深度的剪枝数量对比
Fig. 2 Depth-wise analysis of pruned filters in generator convolutional layers using RICK

本文的主要贡献如下:

1) 提出了一种基于重要性权重的动态剪枝优化方法, 根据网络不同层级在训练过程中的特征演化规律, 自适应调整剪枝比例, 实现更加精准有效的知识迁移, 以解决静态剪枝方法存在的通用特征误删与冗余特征残留问题。

2) 设计了一种重要性累积分布建模机制, 通过累积 Fisher 信息实现滤波器动态筛选, 显著提升了源域到与源域相差较大的目标域适配过程中不兼容特征的剔除能力, 在多个目标域生成任务中表现出更高的真实性与多样性。

3) 在多个跨域 FSIG 基准数据集(如 Babies, Sunglasses, Sketches 和 AFHQ-Cat)上开展系统实验, 结果表明本文方法在 FID 与 Intra-LPIPS 等指标上显著优于现有主流方法, 在与源域相差较大的目标域中本方法 FID 优于现有最优方法, 验证了本方法在处理跨域迁移任务中的鲁棒性与有效性。

1 相关工作

FSIG 旨在从有限的训练样本中学习目标数据的分布, 并生成具有多样性和真实感的图像。在数据有限的情况下, 直接训练生成模型往往会导致模型过拟合, 并降低生成图像的质量和多样性。因此, 近年来, 研究人员探索了多种知识迁移和正则化方法, 以提高 FSIG 任务的性能。

迁移学习是一种被广泛应用的技术, 近年来, 迁移学习也逐渐被引入生成任务, 特别是在 FSIG 领域。基于迁移学习的 FSIG 方法旨在将预训练生成模型在大规模源域中学到的知识, 快速高效地迁移至数据有限的目标域。理想情况下, 适应后的生成模型应同时具备以下能力:

1) 保留源域生成模型中对于跨域分布变化具有鲁棒性的属性, 如整体结构、合成多样性及语义变化能力;

2) 充分建模目标域内部数据分布, 生成符合目标域分布的新样本。

早期阶段, WANG 等^[25]首次将迁移学习引入 FSIG 任务, 通过全参数微调策略(Transferring GANs, TGAN)实现预训练模型到目标域的基础适配, 但这种直接策略可能导致过拟合。为解决过拟合和微调过程中的训练稳定性问题, MO 等^[26]创新性地提出了判别器低层参数冻结策略(Freeze the Discriminator, FreezeD), 有效抑制梯度异常波动; 与此同时, LI 等^[27]引入弹性权重巩固机制(Elastic Weight Consolidation, EWC), 基于 Fisher 信息矩阵量化参数重要性, 从而缓解了灾难性遗忘问题。为进一步提升生成多样性, 文献[23]提出了跨域距离一致性损失(Cross-Domain Correspondence, CDC), 通过保持源域样本间的相对结构关系实现隐式知识迁移。在此基础上, XIAO 等^[28]构建松弛空间结构对齐约束(Relaxed Spatial Structural Alignment, RSSA), 并结合潜在空间压缩正则化策略, 显著缓解极低样本量(如仅 5 张图片)下的模型过拟合现象。ZHAO 等^[29]通过构建双向对比学习框架(Dual Contrastive Learning, DCL), 在潜在变量与图像空间实施互信息最大化约束, 显著强化跨域语义对齐效果。面对源域与目标域分布差异较大的场景, ZHAO 等^[30]设计了自适应核调制模块(Adaptation-Aware Kernel Modulation, AdAM), 通过动态分析卷积核迁移贡献度实现参数选择性迁移, 大幅提升跨域生成鲁棒性。针对不兼容特征迁移问题, 文献[22]

进一步提出了去除不兼容知识算法(Removing in-Compatible Knowledge, RICK), 系统性地剔除预训练模型中与目标域冲突的冗余成分, 在提升生成质量的同时增强风格一致性。PAN 等^[31]融合风格引导提示机制与多层次对比损失函数, 在保持内容结构连贯性的同时实现细粒度风格迁移, 为极端小样本(如仅 1 张图片)条件下的高质量生成提供了新的解决方案。

近年来, 扩散模型(Diffusion Models, DMs)在图像生成领域取得了显著突破。其基本思想是学习一个随机过程, 并将纯噪声分布转化为近似给定数据的复杂分布。针对 FSIG 任务, 已有研究开始探索将 DMs 引入该领域。

MOON 等^[32]提出 A³FT (Adapter-Augmented Attention Fine-Tuning)方法, 通过实证分析发现, DMs 中的注意力模块对快速适应新域具有关键作用, 仅微调注意力模块即可在很大程度上缓解过拟合现象。在此基础上, 又引入了时间感知适配器, 动态调节注意力模块内的特征表示, 使得模型在处理不同时间步时能够更好地适配目标域分布, 增强生成多样性与细节质量。ZHU 等^[33]进一步设计了成对约束适配方法(DDPM Pairwise Adaptation, DDPM-PA), 通过保持生成样本间的相对成对距离, 有效保留源域信息和生成多样性, 从而增强了小样本下的生成效果。近期, CAO 和 GONG^[34]提出了一种无需额外训练的条件松弛扩散反演策略(Conditional Relaxing Diffusion Inversion, CRDI), 利用样本级引导嵌入, 动态引导生成过程, 通过动态噪声调度增强生成多样性, 有效规避了微调引发的过拟合问题, 显著提升了扩散模型在小样本目标域中的生成质量和多样性表现。

尽管已有研究推动了扩散模型在 FSIG 任务中的应用, 但仍存在诸多挑战: 模型参数规模大, 易导致过拟合; 缺乏明确可控的潜在空间, 限制了迁移能力; 生成多样性在小样本条件下易退化。此外, 扩散模型在 FSIG 场景下尚缺乏成熟统一的适配方法体系, 跨域泛化能力仍有待进一步提升^[19]。

2 方法

2.1 背景知识

在 FSIG 任务中, 迁移学习已成为主流策略, 常通过将源数据上预训练的 GAN 适配至目标域, 以缓解目标数据不足问题。以源生成器 G_s 与判别

器 D_s 的参数作为初始化, 结合少量目标样本微调得到目标生成器 G_t 和判别器 D_t , 优化对抗损失以提升目标域图像的质量与多样性, 即

$$\begin{aligned} & \min_{G_t} \max_{D_t} L_{\text{adv}} \\ & = \mathbb{E}_{x \sim p_{\text{data}}(x)} [\log D_t(x)] + \mathbb{E}_{z \sim p_z(z)} [\log(1 - D_t(G_t(z)))] \quad (1) \end{aligned}$$

式中: $p_z(z)$ 表示噪声分布; $p_{\text{data}}(x)$ 表示目标域的真实数据分布。

现有方法大多默认微调能够自动排除源域中与目标语义冲突的不兼容特征, 但在源域与目标域差异显著时(如人脸→猫脸), 这类假设难以成立, 易引入伪影或风格错配等问题。RICK 方法针对该问题, 分析出迁移到目标域的不兼容特征与源域重要性较低的滤波器有关, 提出了通过剪枝源生成器中重要性最低的滤波器以移除不兼容特征, 并在实践中表现出一定成效。

具体而言, RICK 采用基于 Fisher 信息的滤波器重要性度量, 每层剪枝固定比例(如 0.1%)的低重要性滤波器以去除冗余成分。该方法虽在源域与目标域相差不大的场景下能有效缓解不兼容迁移问题, 但由于采用固定剪枝比例, 忽视了卷积网络中不同层在训练过程中的功能: 浅层更关注通用纹理特征, 深层则逐步捕捉高语义特征, 不同深度层重要性会随训练阶段动态变化。

然而, RICK 对所有层采用固定剪枝比例, 会导致浅层特征误删、深层冗余残留的问题: 一方面削弱了模型适应能力, 另一方面降低了生成图像的真实性与稳定性。因此, 固定比例策略难以匹配各层重要性与训练动态性之间的关系。

为克服这一问题, 本文提出了基于重要性权重的动态剪枝方法, 利用 Fisher 信息度量滤波器在不同训练阶段的贡献度, 自适应调整各层剪枝比例, 实现更精确的不兼容特征剔除。该方法可进一步提升跨域小样本场景下图像生成的稳定性与质量。

2.2 基于重要性权重动态剪枝的小样本生成方法

在小样本跨域图像生成任务中, 给定预训练的源域生成器 G_s 和判别器 D_s , FSIG 的目标是通过有限的目标域样本 $D_T = \{x_i\}_{i=1}^k$ (通常 $k \leq 100$), 适配得到能够生成符合目标域分布的生成器 G_t 。

为提升 G_t 在与源域差异较大的目标域场景下的适配能力与生成效果, 本文提出了一种基于重要性权重的动态剪枝方法(Dynamic Accumulative Pruning, DAP), 利用训练过程中各层滤波器对应的 Fisher 信息, 估计其对当前任务的贡献度, 并通过

构建 Fisher 信息的累积分布自适应地确定剪枝阈值, 从而实现不同训练阶段的重要性筛选, 精准剔除冗余或不兼容特征, 促进语义特征的有效迁移。

2.2.1 整体框架

如图 3 所示, 本方法以 GAN 框架为基础, 通过动态剪枝方法优化生成器在跨域小样本场景下的适配能力, 整体流程涵盖生成、重要性评估与剪枝优化 3 个核心阶段: ①目标域模型以源域中训练好的模型作为初始化, 目标域生成器 G 接收随机噪声 z 并生成图像 $G(z)$, 判别器 D 通过对比生成图像与目标域少量的真实图像 x 计算对抗损失 L_G , 驱动梯度反向传播以更新生成器中的滤波器参数。在重要性度量阶段, 本方法每隔一定的迭代次数使

用基于滤波器的 Fisher 信息度量各层级滤波器的重要性; 同时通过由大到小排序、累加和计算确定剪枝阈值, 并更新记忆库以存储需要被裁剪的低重要性滤波器的索引; ②在剪枝阶段, 结合记忆库中存储的需要被剪枝的滤波器索引, 通过置零操作裁剪 Fisher 信息低于阈值的滤波器。被裁剪的滤波器索引将一直保存在记忆库中, 后续不会进行梯度更新。剪枝后的生成器在保留源生成器跨域通用特征的同时, 剔除了与目标域不兼容的语义特征, 进一步提升生成图像的真实性与多样性; ③优化后的生成器与判别器在对抗损失引导下迭代更新, 通过动态调整每一训练轮次的剪枝阈值, 平衡模型复杂度与生成质量。

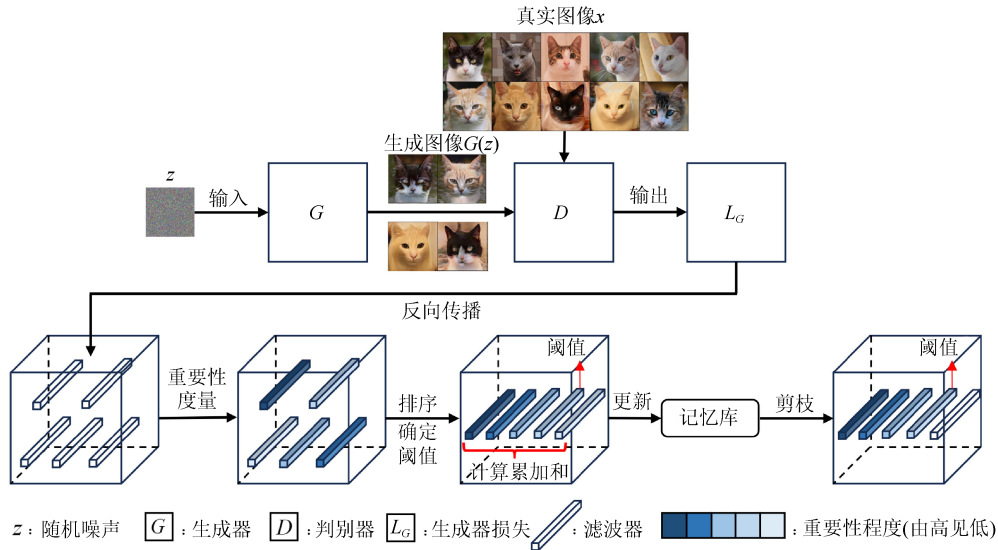


图 3 基于重要性权重动态剪枝的小样本图像生成框架图

Fig. 3 Framework of few-shot image generation based on importance-weighted dynamic pruning

2.2.2 重要性度量

1) 生成器的卷积层。为了度量每个滤波器在迁移中的重要性, 本文基于生成器的反向传播信息, 使用一阶近似 Fisher 信息来估计每个滤波器的参数重要性。具体而言, 假设滤波器可表示为

$$W \in \mathbf{R}^{c^m \times k \times k} \quad (2)$$

式中: c^m 表示输入特征图的通道数; k 表示滤波器的空间尺寸。本研究利用生成器训练过程中的梯度信息, 计算滤波器 W 的 Fisher 信息, 即

$$F_G^{(\text{conv})}(W) = \mathbb{E} \left[-\frac{\partial^2}{\partial W^2} L_G(x|W) \right] \quad (3)$$

式中: L_G 表示生成器的损失函数, 以判别器输出的二值交叉熵损失; x 表示生成图像。在实际实现中, 为了降低计算复杂度, 本文沿用了 RICK 的设

定, 采用一阶近似形式, 即使用每轮训练过程中反向传播得到的梯度平方作为 Fisher 信息的估计值, 即

$$F_G^{(\text{conv})}(W) \approx \mathbb{E} \left[\left(\frac{\partial L_G}{\partial W} \right)^2 \right] \quad (4)$$

通过对多个样本进行平均, 可获得稳定的 Fisher 估计, 从而为后续的剪枝筛选提供依据。

2) 生成器的全连接层。对于生成器的全连接层(调制权重 $W_G^{(fc)}$ 和偏置 $\theta_G^{(fc)}$), 采用联合 Fisher 信息计算, 即

$$F_G^{(fc)} = \frac{1}{2} \left(\mathbb{E} \left[\left(\frac{\partial L}{\partial W_G^{(fc)}} \right)^2 \right] + \mathbb{E} \left[\left(\frac{\partial L}{\partial \theta_G^{(fc)}} \right)^2 \right] \right) \quad (5)$$

随后对生成器的全连接层执行与卷积层相同的动态剪枝策略。

3) 判别器。判别器的处理需考虑其层级结构的特殊性。对于残差块中的卷积层, 首先提取其权重 \mathbf{W} 和对应偏置 θ 的 Fisher 信息, 即

$$\mathbf{F}_D^{(\text{conv})} = \frac{1}{2} \left(\text{mean}(\mathbf{F}(\mathbf{W}_D^{(\text{conv})})) + \mathbf{F}(\theta_D^{(\text{conv})}) \right) \quad (6)$$

随后对判别器执行与生成器卷积层相同的剪枝流程。

2.2.3 确定剪枝阈值

对于生成器的卷积层, 设第 l 层包含 N_l 个滤波器, 其 Fisher 信息矩阵为 $\mathbf{F}^{(l)} \in \mathbf{R}^{N_l}$ 。与 SOTA 方法直接利用分位数求阈值不同, DAP 执行以下步骤:

1) 全局信息聚合。将生成器所有卷积层的 Fisher 信息拼接为向量 $\mathbf{F}_{\text{conv}} = \{\mathbf{F}^{(l)}\}_{l=1}^L \in \mathbf{R}^{\sum N_l}$, 并按降序排列得到 $\mathbf{F}_{\text{sorted}}$ 。

2) 累积分布建模。计算累积重要性权重

$$S(k) = \frac{\sum_{i=1}^k \mathbf{F}_{\text{sorted}}(i)}{\sum_{j=1}^N \mathbf{F}_{\text{sorted}}(j)} \quad (7)$$

式中: $S(k)$ 表示前 k 个高 Fisher 信息滤波器的归一化累积贡献值, 反映其在全部滤波器中的相对重要性; $\mathbf{F}_{\text{sorted}}(i)$ 表示第 i 个滤波器的 Fisher 信息。

3) 动态阈值确定。给定预设的累积比例 α , 寻找最小索引 k^* , 使得

$$S(k^*) \geq 1 - \alpha \quad (8)$$

则剪枝阈值确定为

$$\mathbf{T}_{\text{prune}}^{\text{conv}} = \mathbf{F}_{\text{sorted}}(k^*) \quad (9)$$

2.2.4 依据动态阈值剪枝

在获得每个滤波器的重要性估计和阈值选取后, 本文依据 Fisher 信息值对滤波器进行分类处理, 并采用冻结、微调和剪枝三阶段参数控制策略, 以实现结构语义特征的保持与不兼容特征的有效剔除。具体而言, 所有滤波器根据 Fisher 值从高到低排序, 划分规则如下:

1) 冻结滤波器。Fisher 信息高于保留阈值的部分。为确保对比实验的一致性, 本文保持冻结阈值设置与 RICK 方法一致, 以便客观比较本文提出的动态剪枝方法的有效性。

2) 微调滤波器。Fisher 信息位于保留阈值与剪枝阈值之间, 保留一定适应能力, 根据式(1)参与常规梯度更新。

3) 剪枝滤波器。Fisher 信息低于动态计算得到

的剪枝阈值, 认为其冗余或与目标域语义不兼容, 在训练中将其权重及梯度置零。

参数控制策略在每轮训练中动态更新, 有效抑制不兼容特征对目标域学习的干扰, 提升模型的稳定性与泛化能力。需要指出的是, 已被判定为剪枝的滤波器在后续迭代中将被持续屏蔽, 其权重与梯度始终置零, 有效避免冗余滤波器反复干扰生成过程, 从而增强剪枝策略的稳定性与执行效率。

3 实验

3.1 实验设置

为确保公平性, 本文严格遵循已有文献中的实验配置方案^[22], 包括源域与目标域的选择以及小样本目标数据的配置。与现有方法一致, 本研究采用 StyleGAN-V2 作为预训练与域适应阶段的 GAN 架构。在模型适应阶段, 统一使用像素分辨率为 256×256 的图像。所采用的基线方法已在第 1 节“相关工作”中进行说明。所有模型的训练均在配备 NVIDIA RTX A6000(40 GB 显存)的服务器上完成。

3.2 数据集介绍

源域人脸数据集(Flickr-Faces-HQ, FFHQ)到相关人脸目标域。FSIG 方法通常需要在源域与目标域存在不同程度接近性的设置下进行评估。本文使用 FFHQ 数据集作为源域, 其包含 70 000 张多样化高质量人脸图像, 覆盖不同年龄、性别、姿态和表情变化, 被广泛用于生成模型的预训练。首先在源域数据集上训练生成模型获得高质量的预训练模型, 随后将其迁移至不同目标域进行适应。目标域选用 Babies(婴儿脸图像)、Sunglasses(佩戴墨镜的人脸图像)和 Sketches(肖像素描图像)数据集。如图 4 所示, Babies 数据集包含人脸结构变化,

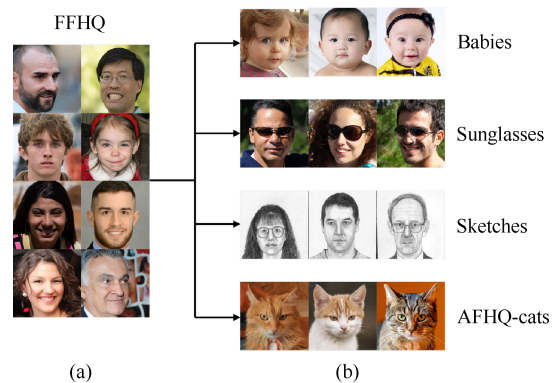


图 4 源域与目标域示意图((a) 源域; (b) 目标域)
Fig. 4 Illustration of source and target domains((a) Source domain; (b) Target domain)

Sunglasses 数据集包含局部风格(佩戴墨镜)与整体光照风格变化, Sketches 数据集相比 FFHQ 整体风格变化更加显著。

源域人脸数据集(FFHQ)到不相关动物脸目标域。除了在相关目标域中的迁移性能, FSIG 方法在源域与目标域存在显著差异的场景下的表现同样关键。为此, 本文将预训练于 FFHQ 的生成器迁移至 AFHQ-Cat(猫脸图像)目标域, 以全面评估模型在不同程度的结构、风格和语义差异跨度下的适应能力。训练阶段每个目标域仅在数据集中随机挑选 10 张图像。

3.3 评价指标

本文采用 FID (Fréchet Inception Distance)和 Intra-LPIPS (Intra-domain Learned Perceptual Image Patch Similarity)作为核心评价指标, 从生成图像的真实性 and 多样性 2 个维度进行量化评估。最后, 本文将生成的图像可视化, 使用固定的噪声输入与不同的方法进行公平比较。

3.3.1 FID 指标

通过计算生成图像与真实图像在 Inception-v3 特征空间的分布距离, 衡量生成质量。其定义为

$$FID = \|\mu_r - \mu_g\|^2 + Tr(\Sigma_r + \Sigma_g - 2\sqrt{\Sigma_r \Sigma_g}) \quad (10)$$

式中: μ_r 和 Σ_r , μ_g 和 Σ_g 分别表示真实图像和生成图像在 Inception-v3 最后一层池化特征(2 048 维)的均值向量与协方差矩阵。FID 值越小, 生成分布与真实分布越接近。由于该指标对小样本场景下协

方差矩阵的扰动敏感, 可有效反映数据稀缺时的模型泛化能力。

3.3.2 Intra-LPIPS 多样性指标

通过预训练的 AlexNet 提取多层次特征, 计算同一类别内生成图像两两之间的平均感知差异, 即

$$I = \frac{1}{C} \sum_{c=1}^C \left(\frac{2}{N_c(N_c-1)} \sum_{i=1}^{N_c} \sum_{j>i}^{N_c} LPIPS(x_i^c, x_j^c) \right) \quad (11)$$

式中: C 表示类别数; N_c 表示第 c 类的生成样本数; $LPIPS(\cdot)$ 表示基于特征空间余弦距离的感知相似度计算函数。该值越高, 表明模型在有限样本下生成的类内多样性越强。相较于像素级指标, $LPIPS$ 通过引入深度特征对齐人类视觉感知, 可更好区分生成结果的模式重复性问题。

3.3.3 定性评价

在可视化对比实验中, 本文展示了不同方法在 Babies 和 AFHQ-Cat 数据集中生成图像的效果。需要指出的是, 扩散模型由于生成机制差异, 无法通过与 GAN-based 方法一致的噪声输入生成对比图像, 故未在本节可视化结果中呈现, 与扩散模型的对比分析详见定量评价部分。

3.4 实验结果

3.4.1 定性结果分析

图 5 和图 6 展示了本方法与现有主流 FSIG 方法在 2 个目标域(Babies 和 AFHQ-Cat)上的生成效果对比。每一行对应一种方法, 展示该方法在当前目标域下的生成结果, 便于横向观察其多样性表

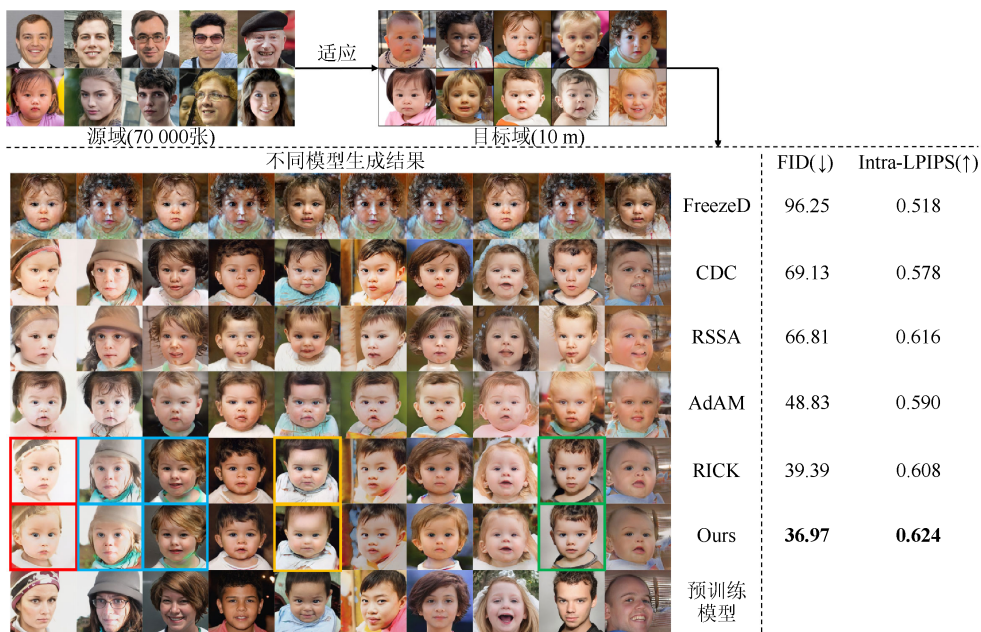


图 5 FSIG 不同方法在 Babies 数据集上的对比结果

Fig. 5 Performance comparison of various FSIG approaches on the Babies dataset

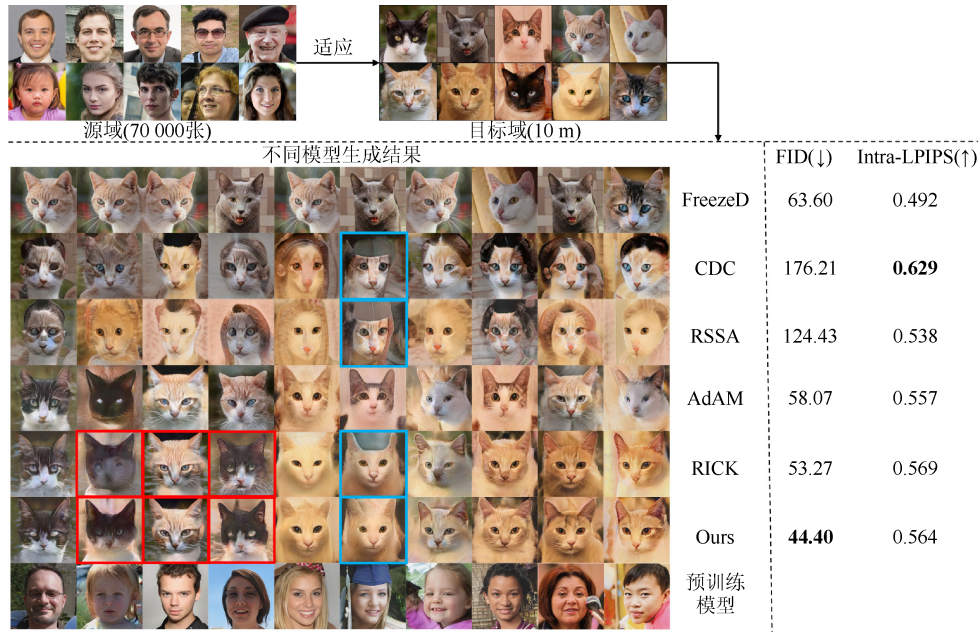


图 6 FSIG 不同方法在 AFHQ-Cat 数据集上的对比结果

Fig. 6 Performance comparison of various FSIG approaches on the AFHQ-Cat dataset

现。每一列对应相同噪声输入下，不同方法生成的图像，便于纵向对比生成图像的真实性。为方便整体对比，2个图的最后一行补充展示了预训练模型的生成图像结果。同时，图右侧列出了各方法的 FID 和 Intra-LPIPS 指标，进一步对比评估生成性能。

在 Babies 数据集上，FreezeD 方法由于完全冻结源域深层特征，只做浅层调整，导致无法适应目标域特征分布，生成图像存在明显过拟合现象。CDC, RSSA 和 AdAM 方法生成质量较差。如图 5 红框所示，RICK 生成图像在边缘区域呈现明显模糊现象，且面部细节重建不足，由于 RICK 方法采用固定的剪枝比例，导致了低层卷积层中过多滤波器被剪枝，进而损害边缘与纹理的表达能力。而本文提出的动态剪枝方法能够自适应地调整训练不同阶段的剪枝比例，特别是在低层中更好地保留关键特征，因此生成图像在人脸轮廓与细节表达上明显更为清晰丰富。如图 5 蓝框所示，RICK 在生成结果中仍保留源域不兼容的面部纹理特征(如成人面部皱纹)，导致生成的婴儿脸不够自然、真实性降低。而本方法在去除源域不兼容特征方面表现更为优异，所生成的婴儿图像更为自然、细腻，肤质细节表现更接近真实图像。在黄框图像中，RICK 方法生成的婴儿脸额头区域存在明显伪影，本方法则显著减弱了此类伪影的产生，表现出更优的稳定性，且生成结果在视觉一致性方面更加理想。

而绿框图像中，尽管 RICK 在一定程度上抑制了源域胡须等不兼容特征，但仍残留部分伪影；相比之下，本方法能够实现更加彻底与干净地去除不兼容特征。

在跨域差异显著的 AFHQ-Cat 数据集上，本方法的优势更为突出。图 6 红框图像中，相较于 RICK，本方法在毛发边缘、眼部、嘴部等区域保留了更多细节信息，整体视觉效果更加逼真。图 6 蓝框图像中，CDC 与 RSSA 均无法有效去除源域残留的帽子等不兼容特征，RICK 方法对此仅表现出轻微抑制，而本方法则可实现对该类不兼容特征的彻底去除，生成图像更加符合目标域分布，显著提高了真实性。

综上所述，本文提出的动态剪枝方法在保证低层语义特征保留的同时，有效去除了源域不兼容特征，在多个评估指标(FID 与 Intra-LPIPS)上均取得最佳性能，且在视觉质量与多样性方面均表现出领先的综合能力。

3.4.2 定量结果分析

除定性结果外，本文进一步从定量角度对比不同方法的性能表现。定量评估在 Babies, Sunglasses, Sketches 和 AFHQ-cat 数据集的完整集合上进行，分别包含约 2 500, 2 700, 300 和 5 000 张图像。本研究使用训练好的生成器随机生成 5 000 张图像，并与整个目标数据集进行比较以计算 FID。表 1 展示了 4 个基准数据集的完整 FID 结果。

表 1 FSIG 各方法在不同目标域的 FID(\downarrow)结果

方法	Backbone	Babies	Sunglasses	Sketches	AFHQ-Cat
TGAN ^[25]	StyleGAN	101.58	55.97	53.41	64.68
TGAN+ADA ^[12]	StyleGAN	97.91	53.64	66.99	80.16
FreezeD ^[26]	StyleGAN	96.25	46.95	46.54	63.60
CDC ^[23]	StyleGAN2	69.13	41.45	45.67	176.21
DCL ^[29]	StyleGAN2	56.48	37.66	57.72	156.82
EWC ^[27]	StyleGAN2	79.93	49.41	71.25	74.61
DDPM-PA ^[33]	DDPM	48.92	34.75	—	—
AdAM ^[30]	StyleGAN2	48.83	28.03	<u>38.11</u>	58.07
RICK ^[22]	StyleGAN2	<u>39.39</u>	25.22	40.52	<u>53.27</u>
CRDI ^[34]	DDPM	48.52	<u>24.62</u>	—	—
DAP(Ours)	StyleGAN2	36.97	24.13	37.96	44.40

注: 加粗数据表示最优值; 下划线数据表示次优值。

表 1 为本方法与多种主流 FSIG 方法在 4 个目标域(Babies, Sunglasses, Sketches, AFHQ-Cat)上的 FID 指标对比结果。可以观察到, 本方法在全部目标域均取得了最优 FID 结果, 整体性能优于现有基于 GAN 的方法与基于 DMs 的方法。

在 Babies(人脸 \rightarrow 婴儿脸)和 Sunglasses(人脸 \rightarrow 戴墨镜的人脸) 2 个结构迁移和局部风格迁移场景中, 本方法有效降低了 FID, 表现出优异的跨域适应能力和稳定性。其中, 本方法在 Babies 数据集的 FID 相较次优结果 RICK 降低了 2.42, 在 Sunglasses 数据集的 FID 相较次优结果 CRDI 降低了 0.49。

由表 1 可以观察到, 现有基于扩散模型的方法(如 DDPM-PA 和 CRDI)在小样本条件下与基于 GAN 的方法仍存在一定差距。由于 DDPM-PA 的优化目标偏向提升生成多样性, 缺乏明确的结构一致性保障, 导致在 Babies 任务中生成图像的细节结构一致性不足; 同时, 其高频增强模块基于全图处理, 缺乏对局部风格属性的精准控制, 在 Sunglasses 任务中局部风格迁移存在明显局限性。针对此问题, CRDI 方法通过免微调(Training-free)策略, 利用样本引导嵌入(Sample-Wise Guidance Embedding, SGE)引导反向采样过程, 能够在局部风格迁移场景(如 Sunglasses 数据集)中具备一定生成优势, 进步较大。然而, SGE 为单样本引导, 缺乏全局目标域建模能力, 难以覆盖 Babies 任务中跨个体细节变化的特征分布, 此外, 其多样性增强阶段引入的噪声扰动存在源域信息残留问题, 影响生成图像的目标域一致性。

对于 Sketches(人脸 \rightarrow 肖像素描)目标域, 该场景风格差异显著, 本方法仍保持领先, 取得最低 FID, 相较次优结果 AdAM 降低 0.15, 体现出良好的风格迁移能力。

在最具挑战性的 AFHQ-Cat 目标域, 源域与目标域之间存在极大语义差异(人脸 \rightarrow 动物脸), 传统基于 GAN 的方法存在明显性能退化, 本方法通过动态剪枝机制有效提升了源域与目标域相差较大场景下的语义迁移能力, FID 相较次优结果 RICK 下降了 8.87, 展现出较强的泛化性能。整体来看, 本方法在结构迁移、风格迁移和大跨域语义迁移等不同任务中均保持领先, 具有较强的跨域适应性和稳定性。该结果进一步验证了本方法在 FSIG 任务中的优越性能。

3.5 与 RICK 方法的设计对比

本节将 DAP 与 RICK 从剪枝策略的核心逻辑到实际剪枝效果进行了深入对比。

RICK 方法采用固定百分位的剪枝策略, 直接依据全局 Fisher 信息分布设定剪枝阈值。这种静态量化方式无法感知不同层之间的重要性差异, 易出现浅层重要特征被误剪, 深层冗余特征保留的问题。而本文提出的动态剪枝方法基于累积重要性排序, 在计算 Fisher 信息总和的基础上, 按照累积重要性权重自适应设定剪枝阈值, 能够精准地控制整体保留信息量, 并适应不同目标域数据集的实际分布, 从而显著提升剪枝决策的灵活性与稳定性。

图 7 展示了本方法与 RICK 在 Sketches 数据集上的可视化对比实验结果。从图中可以看到, RICK 方法生成结果在整体轮廓呈现上存在明显失真, 部分人脸结构被错误描绘, 且在细节层面出现明显偏差, 如多处未戴眼镜的源域图像在生成结果中被错误地添加了眼镜; 而本方法能够在保持 Sketches 风格特征的同时, 更准确地保留源图像中的结构信息, 在人物轮廓、五官结构、是否佩戴眼镜等细节层面均与源域图像保持良好一致性, 显示出更高的结构与风格一致性。

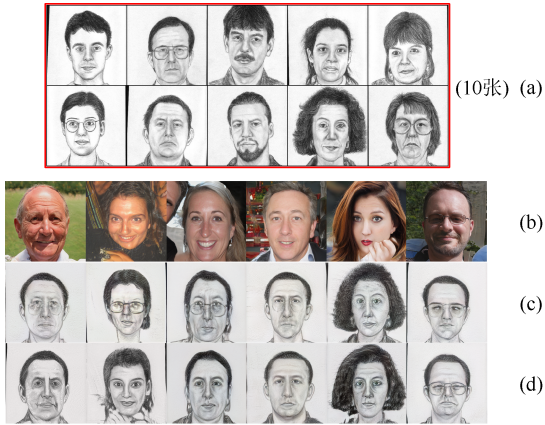


图 7 RICK 与 DAP 在 Sketches 数据集上的风格迁移能力对比((a) 目标域; (b) 源域; (c) RICK; (d) 本文方法)
 Fig. 7 The comparison of style transfer ability between RICK and DAP on the Sketches dataset ((a) Target domain; (b) Source domain; (c) RICK; (d) Our method)

另外, 本文对比分析了所提 DAP 方法与 RICK 在 AFHQ-cat 数据集实验中, 生成器不同深度层(浅层、中层、深层)的剪枝数量变化。图 8 展示了 2 个方法在训练过程中被剪滤波器数量的变化趋势。




图 8 生成器卷积层中 DAP 与 RICK 的剪枝数量分层对比 ((a) 浅层; (b) 中层; (c) 深层)

Fig. 8 Layer-wise Comparison of pruned filters between DAP and RICK in generator convolutional layers ((a) Shallow layer; (b) Middle layer; (c) Deep layer)

如图 8(a)所示, 在浅层网络中, RICK 在大部分训练阶段保持了稳定的剪枝量(2~4 个滤波器), 呈现静态、平稳的裁剪行为; 而 DAP 在初期保持保守策略以避免误删通用纹理特征, 随后逐步增加剪枝幅度, 在后期达到更高的剪枝能力。结合图 1 浅层 Fisher 信息占比逐渐下降的趋势, 这一特性体现了本方法更强的动态适应能力与通用特征保留能力。

如图 8(b)所示, 在中层网络中, DAP 展示出明显的逐步增强趋势, 剪枝数量随训练逐渐上升, 说明模型能够逐步识别中层冗余通道并剔除。相比之下, RICK 方法剪枝数量较为平稳, 缺乏对参数重要性变化的响应能力, 易出现对冗余特征保留过多的问题。

如图 8(c)所示, 在深层网络中, RICK 方法在训练后期对重要性占比高的深层网络执行剪枝操作, 结合图 1 深层 Fisher 信息在训练后期大幅增长, 重要性占比显著升高的趋势, 这会对模型高层语义表示能力造成破坏; 而 DAP 在训练中期之后几乎不对深层进行剪枝, 体现出其更谨慎地保留深层语义通道, 有助于提升图像结构与内容一致性。

综上所述, 经理论分析与实验验证, 本方法不仅在剪枝策略设计上更具理论优势, 在实际训练过程中也展现出更稳健合理的剪枝行为。

3.6 消融实验


为了进一步验证本方法的通用性与有效性, 将 DAP 应用于现有的核调制方法 AdAM 中。AdAM 通过调制机制在目标域上估计生成器卷积核参数的重要性, 在此基础上引入动态剪枝策略, 以减轻源域不兼容特征对目标域生成质量的干扰。表 2 所示与原始 AdAM 方法相比, 集成本方法后的 AdAM+DAP 在 4 个目标域上均取得了性能提升, 其中在与源域差异显著的 AFHQ-Cat 上提升尤为明显。

为了验证本方法中累积比例超参数 α 的合理性, 本研究在不同数据集上分别进行了多组累积比例的对比实验。图 9 展示了在每次迭代中不同超参数 α 设置下, 模型在不同数据集上的性能变化情况。

可以看出, 随着 α 的增加, 各目标域的生成性能整体呈现不同程度的波动。其中, 在与源域相差较大的目标域 AFHQ-Cat 上, FID 对 α 较为敏感, 过高或过低的比例都会导致性能明显下降, 说明该场景下对结构特征保留的要求更高; 在相对容易的 Sunglasses 和 Babies 目标域中, 模型表现更为稳定。最终本研究选定的最佳累积比例能够在 4 个目标

表 2 DAP 方法应用于 AdAM 方法的消融实验结果

方法	Backbone	Babies	Sunglasses	Sketches	AFHQ-Cat
AdAM ^[30]	StyleGAN2	48.83	28.03	38.11	58.07
AdAM+DAP(Ours)	StyleGAN2	46.14(-2.69)	25.57(-2.46)	38.06(-0.05)	50.12(-7.95)

图 9 超参数 α 对各目标域 FID 的影响Fig. 9 Impact of hyperparameter α on FID scores across different target domains

域上同时取得最优的 FID 值, 验证了该设置的通用性与有效性。

4 结论

针对 FSIG 任务中源域与目标域知识迁移不兼容的挑战, 本文提出了一种基于重要性权重动态剪枝的方法。该方法在训练过程中利用 Fisher 信息衡量各卷积层滤波器对生成性能的重要程度, 并根据累积的重要性权重动态调整不同训练阶段各层的剪枝比例, 通过及时剪枝重要性低的滤波器, 从而能够在保留跨域通用语义信息的同时, 更加有效地剔除源域中与目标域不兼容的语义特征。实验结果显示, 该方法在多个跨域 FSIG 任务中均取得优异表现, 尤其在挑战性的 AFHQ-Cat 数据集上, FID 相较现有最优方法降低了 8.87, 验证了其在提升生成质量与迁移鲁棒性方面的有效性。本方法存在累积剪枝比例依赖人工设定的局限, 缺乏统一且自适应的调节机制。未来工作将探索无需超参数的自适应剪枝阈值学习机制, 以实现完全自动化的剪枝决策过程, 进一步提升模型的泛化能力和训练效率。

参考文献 (References)

[1] GOODFELLOW I J, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial nets[C]//The 28th International Conference on Neural Information Processing Systems. Cambridge: MIT Press, 2014: 2672-2680.

[2] KARRAS T, LAINE S, AITTALA M, et al. Analyzing and improving the image quality of StyleGAN[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. New York: IEEE Press, 2020: 8107-8116.

[3] 邵俊棋, 钱文华, 徐启豪. 基于条件残差生成对抗网络的风景区生成[J]. 图学学报, 2023, 44(4): 710-717.

SHAO J Q, QIAN W H, XU Q H. Landscape image generation based on conditional residual generative adversarial network[J]. Journal of Graphics, 2023, 44(4): 710-717 (in Chinese).

[4] 古天骏, 熊苏雅, 林晓. 基于 SASGAN 的戏剧脸谱多样化生成[J]. 图学学报, 2024, 45(1): 102-111.

GU T J, XIONG S Y, LIN X. Diversified generation of theatrical masks based on SASGAN[J]. Journal of Graphics, 2024, 45(1): 102-111 (in Chinese).

[5] LIN J, ZHANG R, GANZ F, et al. Anycost GANs for interactive image synthesis and editing[C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition. New York: IEEE Press, 2021: 14981-14991.

[6] WANG T F, ZHANG Y, FAN Y B, et al. High-fidelity GAN inversion for image attribute editing[C]//2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition. New York: IEEE Press, 2022: 11369-11378.

[7] 刘宗明, 洪唯, 龙睿, 等. 基于自注意力机制的乳源瑶绣自动生成与应用研究[J]. 图学学报, 2024, 45(5): 1096-1105.

LIU Z M, HONG W, LONG R, et al. Research on automatic generation and application of Ruyuan Yao embroidery based on self-attention mechanism[J]. Journal of Graphics, 2024, 45(5): 1096-1105 (in Chinese).

[8] CHAI L, ZHU J Y, SHECHTMAN E, et al. Ensembling with deep generative views[C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition. New York: IEEE Press, 2021: 14992-15002.

[9] TRAN N T, TRAN V H, NGUYEN N B, et al. On data augmentation for GAN training[J]. IEEE Transactions on Image Processing, 2021, 30: 1882-1897.

[10] GONG J, FOO L G, FAN Z P, et al. DiffPose: toward more reliable 3D pose estimation[C]//2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition. New York: IEEE Press, 2023: 13041-13051.

[11] AFRASIYABI A, LAROCHELLE H, LALONDE J F, et al. Matching feature sets for few-shot image classification[C]//2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition. New York: IEEE Press, 2022: 9004-9014.

[12] KARRAS T, AITTALA M, HELLSTEN J, et al. Training generative adversarial networks with limited data[C]//The 34th International Conference on Neural Information Processing Systems. Red Hook: Curran Associates Inc., 2020: 1015.

[13] TSENG H Y, JIANG L, LIU C, et al. Regularizing generative adversarial networks under limited data[C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition. New York: IEEE Press, 2021: 7917-7927.

[14] GONG J, FAN Z P, KE Q H, et al. Meta agent teaming active learning for pose estimation[C]//2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition. New York: IEEE Press, 2022: 11069-11079.

[15] FOO L G, GONG J, FAN Z P, et al. System-status-aware adaptive network for online streaming video understanding[C]//2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition. New York: IEEE Press, 2023: 10514-10523.

[16] 张彬, 周粤川, 张敏, 等. 生成对抗网络改进角度与应用研究综述[J]. 计算机应用研究, 2023, 40(3): 649-658.

ZHANG B, ZHOU Y C, ZHANG M, et al. Review of research

- on improvement and application of generative adversarial networks[J]. *Application Research of Computers*, 2023, 40(3): 649-658 (in Chinese).
- [17] 孙龙飞, 刘慧, 杨奉常, 等. 面向医学图像层间插值的循环生成网络研究[J]. *图学学报*, 2023, 44(3): 502-512.
SUN L F, LIU H, YANG F C, et al. Research on cyclic generative network oriented to inter-layer interpolation of medical images[J]. *Journal of Graphics*, 2023, 44(3): 502-512 (in Chinese).
- [18] HU S X, LI D, STÜHMER J, et al. Pushing the limits of simple pipelines for few-shot learning: external data and fine-tuning make a difference[C]//2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition. New York: IEEE Press, 2022: 9058-9067.
- [19] YANG M P, WANG Z. Image synthesis under limited data: a survey and taxonomy[J]. *International Journal of Computer Vision*, 2025, 133(6): 3689-3726.
- [20] LI H L, ZHU C L, ZHANG Y L, et al. Task-specific fine-tuning via variational information bottleneck for weakly-supervised pathology whole slide image classification[C]//2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition. New York: IEEE Press, 2023: 7454-7463.
- [21] ZHUANG F Z, QI Z Y, DUAN K Y, et al. A comprehensive survey on transfer learning[J]. *Proceedings of the IEEE*, 2021, 109(1): 43-76.
- [22] ZHAO Y Q, DU C, ABDOLLAHZADEH M, et al. Exploring incompatible knowledge transfer in few-shot image generation[C]//2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition. New York: IEEE Press, 2023: 7380-7391.
- [23] OJHA U, LI Y J, LU J W, et al. Few-shot image generation via cross-domain correspondence[C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition. New York: IEEE Press, 2021: 10738-10747.
- [24] 朱宝旭, 刘漫丹, 张雯婷, 等. 高分辨率人脸纹理图全流程生成方法[J]. *图学学报*, 2024, 45(4): 814-826.
ZHU B X, LIU M D, ZHANG W T, et al. Full process generation method of high-resolution face texture map[J]. *Journal of Graphics*, 2024, 45(4): 814-826 (in Chinese).
- [25] WANG Y X, WU C S, HERRANZ L, et al. Transferring GANs: generating images from limited data[C]//The 15th European Conference on Computer Vision. Cham: Springer, 2018: 220-236.
- [26] MO S, CHO M, SHIN J. Freeze the discriminator: a simple baseline for fine-tuning GANs[EB/OL]. [2025-02-30]. <https://arxiv.org/abs/2002.10964>.
- [27] LI Y J, ZHANG R, LU J W, et al. Few-shot image generation with elastic weight consolidation[C]//The 34th International Conference on Neural Information Processing Systems. Red Hook: Curran Associates Inc., 2020: 1332.
- [28] XIAO J Y, LI L, WANG C F, et al. Few shot generative model adaption via relaxed spatial structural alignment[C]//2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition. New York: IEEE Press, 2022: 11194-11203.
- [29] ZHAO Y Q, DING H H, HUANG H J, et al. A closer look at few-shot image generation[C]//2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition. New York: IEEE Press, 2022: 9130-9140.
- [30] ZHAO Y Q, CHANDRASEGARAN K, ABDOLLAHZADEH M, et al. Few-shot image generation via adaptation-aware kernel modulation[C]//The 36th International Conference on Neural Information Processing Systems. Red Hook: Curran Associates Inc., 2022: 1412.
- [31] PAN S D, ZHANG Z Q, WEI K, et al. Few-shot generative model adaptation via style-guided prompt[J]. *IEEE Transactions on Multimedia*, 2024, 26: 7661-7672.
- [32] MOON T, CHOI M, LEE G, et al. Fine-tuning diffusion models with limited data[EB/OL]. [2025-02-30]. <https://openreview.net/pdf?id=0J6afk9DqrR>.
- [33] ZHU J Y, MA H M, CHEN J S, et al. Few-shot image generation with diffusion models[EB/OL]. [2025-02-30]. <https://arxiv.org/abs/2211.03264>.
- [34] CAO Y, GONG S G. Few-shot image generation by conditional relaxing diffusion inversion[C]//The 18th European Conference on Computer Vision. Cham: Springer, 2025: 20-37.