

基于微调扩散模型的智能化衬衫款式图生成

朱伟明, 于家蓓

(浙江理工大学 服装学院, 杭州 310018)

摘要:为提高服装设计产业的效率并降低成本,基于人工智能图像生成技术,通过低秩自适应微调 Stable Diffusion 大模型,实现端到端的款式图快速生成。以衬衫为例,通过分析扩散模型,构建衬衫款式图数据集并进行模型训练,同时采用结构相似性算法和峰值信噪比对生成效果进行量化评估。实验结果表明,微调后的模型在结构相似性算法和峰值信噪比指标上分别提升了 22.69% 和 68.59%,且生成的款式图在结构、构图、风格、细节及线条质量上均显著优于微调前。该方法为服装智能设计提供了高效、低成本的新思路,具备实际推广潜力。

关键词: 人工智能生成内容;扩散模型;微调模型;服装设计;服装款式图

中图分类号: TP 391.41; TS 941.713 **文献标志码:** A **文章编号:** 2096-1928(2025)03-0260-08

Intelligent Shirt Style Drawing Generation Based on Fine-Tuned Diffusion Model

ZHU Weiming, YU Jiabei

(School of Fashion Design and Engineering, Zhejiang Sci-Tech University, Hangzhou 310018, China)

Abstract: This study aims to enhance the efficiency and reduce costs in the apparel design industry by leveraging artificial intelligence image generation technology. An end-to-end rapid generation of garment style drawings is achieved through LoRA fine-tuning of the Stable Diffusion model. Taking shirts as the case study, the technical principles of diffusion models were analyzed. A dedicated shirt style drawing dataset was constructed and utilized for model training. The generation performance was quantitatively evaluated using the structural similarity index (SSIM) and peak signal-to-noise ratio (PSNR). Experimental results demonstrate that the fine-tuned model achieves 22.69% and 68.59% improvements in SSIM and PSNR metrics, respectively. The generated style drawings significantly outperform the baseline model in structural coherence, composition, style consistency, detail fidelity, and line quality. This method provides an efficient and cost-effective approach for intelligent garment design with substantial potential for practical implementation.

Key words: artificial intelligence generated content, diffusion model, fine-tuned model, fashion design, style drawing

人工智能(artificial intelligence, AI)推动服装行业的数字化发展,改变了传统服装设计范式。行业

变化产生智能化的新需求,也催生很多新的理论、模式、产品、方法、业态,引发设计思维方式及方法

收稿日期:2024-01-31; 修订日期:2025-06-02。

作者简介:朱伟明(1972—),男,教授,博士生导师。主要研究方向为数字化服装设计。Email:walterzhu@zstu.edu.cn

体系的变革^[1]。人工智能生成内容(artificial intelligence generated content,AIGC)是一种新型的内容创作方式,它继承专业生产内容(professional generated content,PGC)和用户生成内容(user generated content,UGC)的优点,并充分发挥技术优势,打造全新的数字内容生成与交互形态,人工智能生成内容的高速发展推动着虚实融生趋势下内容创作范式的转化^[2]。人工智能辅助设计能够显著提升平面设计的思维活跃度,从而增强设计的流畅度和设计风格的独特性^[3]。相较于传统的服装款式设计流程,AI能够快速根据提示词条生成设计内容,但也存在生成内容相对随机或是模型无法理解指令语义的问题。

2014 年 AIGC 开始在设计领域有所应用,以生成对抗网络(generative adversarial network,GAN)为代表的深度学习算法的出现,标志着人工智能从决策式向生成式的重大转变。这一突破使 AI 首次具备了创作设计内容的能力,开启了智能设计的新纪元。在技术发展初期,相关应用主要集中在产品设计和工业设计领域。例如,WU J J 等^[4]利用 GAN 模型成功生成了具有特定色彩方案和几何形态的三维椅子设计方案。随着生成算法的持续演进,2017 年提出的循环生成对抗网络(CycleGAN)实现了技术突破^[5]。该网络通过捕捉图像域特征并建立跨域转换机制,相比传统风格迁移方法具有显著优势:①实现了无监督学习的风格转换;②为服装设计师提供了更广阔的创意探索空间。在这一技术推动下,AIGC 在服装设计领域的应用范围不断扩大,目前主要应用于服装图案创新设计^[6]、智能纹样配色系统^[7]以及高精度纺织品图像修复技术^[8]。2020 年,扩散模型(denoising diffusion probabilistic model,DDPM)问世,该模型通过给图像增加高斯噪声破坏原始训练数据,随后通过逆向学习噪声去除过程,实现从随机噪声输入到高质量图像生成的转变^[9],该方法在生成对抗网络的基础上提高了图像生成样本的多样性与真实性。KARAGOZ H F 等^[10]运用扩散模型生成纺织图案并取得了优于基础模型的效果。目前,在国内基于 DDPM 的服饰设计技术正快速发展,其产业应用已领先于相关学术研究,基于 DDPM 模型应用场景主要聚焦于柔性制造中的个性化定制环节,形成了一批具有示范效应的商业应用案例,如微软小冰联合中国纺织信息中心、国家纺织产品开发中心共同研发的人工智能纺织服装图案设计平台。该平台能够实现大规模、多样化、质量稳定的图案按需设计。

综上所述,目前 AIGC 赋能下的图案生成研究成果较为丰富,但作为服装 3 要素之一的款式设计生成却并未出现成熟的内容应用场景。因此,文中通过 LoRA 微调 Stable Diffusion 模型实现款式设计图的快速、批量生成。

1 技术背景

1.1 Stable Diffusion 模型

Stable Diffusion 是由 CompVis、Stability AI 和 LAION 共同开发的一个文本转图像模型,只要简单输入一段文本,Stable Diffusion 就可以迅速将其转换为图像。Stable Diffusion 的训练基于 LAION-5B 子集,即一个包含大量像素为 512×512 的图文模型数据集。该数据集用于潜空间中的模型预训练,使其学习文本与图像之间的语义关系,并能够准确生成与输入文本相匹配的图像。作为可本地部署的开源项目,Stable Diffusion 有着集成度高、社区活跃度高、项目易用性高等诸多优势:①Stable Diffusion 整合了先进的人工智能算法和技术,并集成了多种功能和插件,能够实现各类风格图像的生成和细节调整,且支持自行输入数据集并训练对应风格模型,相较于其他 AI 生成软件具有较高的可控性;②Stable Diffusion 社区活跃度较高,意味着不断有新的创新、漏洞修复和功能改进的可能性;③Stable Diffusion 项目提供了一个用户友好的界面及详细的文档和示例,方便用户进行模型训练和部署。

Stable Diffusion 模型的训练可以被描述为一种先加噪后降噪的过程,具体如图 1^[11]所示。由图 1 可知,原始训练素材图文经过变分自编码器(variational autoencoder,VAE)进行编码成为隐含向量 z ,对图像进行加噪扩散后获得随机高斯噪声 z_T 。在生成图像的过程中,Stable Diffusion 首先会将输入的文本或图像信息经过编码器转化为向量并结合随机噪声 z_T 进入 U 网络(U-Net)。随后在潜空间中通过循环迭代的方式采样,并逐步更新像素值,直到生成最终图像。每次迭代,Stable Diffusion 会根据当前的像素值和附加的文本信息,进行像素值的微调和更新,这种更新基于计算图像梯度和最小化像素值与目标值之间的差距来进行。反复迭代更新后图像像素的排列和分布会被逐渐优化,使得图像与输入的文本信息相匹配并呈现出所期望的内容,即 z_0 需要与向量 z 尽可能相似,从而使得解码后生成的图片能够接近原始图片。




图 1 Stable Diffusion 模型
Fig. 1 Stable Diffusion model

1.2 Stable Diffusion 文生图

Stable Diffusion 通过文本编码器解析输入描述，利用深度学习在潜空间中逐步优化图像特征，经过多次迭代更新像素值，最终生成与文本内容高度匹配的视觉图像。用户输入的目标图像单词经过文本编码器处理转化为机器可理解的 token 编码。编码过程中产生的向量被视为生成图像的条件，生成模型首先在潜空间中引入随机噪声，随后，通过深度学习算法结合采样器进行迭代优化，最终生成的

图像通过解码器进行解码并输出，直观呈现目标文本所描述的信息。然而在图像生成过程中，无法在原有模型的基础上直接生成较为符合预期效果的款式图，具体如图 2 所示。

根据图 2 推测，可能是由于模型原始训练集和款式图存在较大视觉认知层面的偏差，或模型无法正确理解款式图的单词定义，因此，需要对原有的模型进行调整，更新部分参数从而改变图像的生成效果。




图 2 Stable Diffusion 文生图
Fig. 2 Text-to-image diagram of Stable Diffusion

1.3 Stable Diffusion 微调模型的 LoRA 技术

大模型低阶适应 (low-rank adaptation of models, LoRA) 最早是微软研究人员为了解决大语言模型微调而开发的一项技术，后被引入图像生成领域。在此领域，LoRA 技术通过低秩近似方法对预训练网络进行优化调整，使其更好地适应特定图像生成任务。LoRA 对于微调图像生成模型的优势在于以更少的额外参数学习实现对预训练权重的增量更新^[12]。该方法采用参数约束策略，通过冻结部分参数或降低参数维度来减少计算量，以达到减少计算


复杂度、控制模型容量、保留模型表达能力以及抑制噪声和不稳定性效果，即在保证生成质量的同时显著提升训练效率。微调的过程就是通过反向传播更新网络参数的过程，具体原理如图 3^[13] 所示。由图 3 可知，蓝色部分为预训练完成 Stable Diffusion 的模型，LoRA 不直接改动原本模型参数，而是通过增加旁路的方法微调模型，增加了 A 和 B 两个矩阵，对于这两种构造，它们的参数是以正态分布和 0 为初值的，即训练刚开始时附加的参数就是 0。

在训练阶段， W_0 的参数固定不动， B 和 A 的权

重是可训练参数, W_0 输入 x , 同时分配到 B 和 A , 公式为

$$h = W_1 \cdot x + \Delta W \cdot x = W_0 \cdot x + B \cdot A \cdot x。$$
(1)

式中: h 为模型的输出, 可理解为经过计算后得到的特征表示或结果向量; W 为模型原始的预训练权重矩阵, 是模型在大规模数据上预先训练好的参数, A 为 LoRA 低秩分解里的一个矩阵; B 为 LoRA 低秩分解里的另一个矩阵; x 为输入到模型的数据向量, 是模型进行计算的输入依据。



注: $W \in R^{d \times d}$ 为参数矩阵, d 为维度, $R^{d \times d}$ 为 d 行 d 列的实数矩阵; $B=0$ 是初始化为 0 的升维矩阵; r 为噪声向量的维度; $A=N(0, \sigma^2)$ 为 A 矩阵元素从均值为 0、方差为 σ^2 的正态分布中采样; x 为输入向量; h 为模型运算后的输出向量。

图3 LoRA 原理
Fig.3 LoRA principles

LoRA 技术只需在预训练模型基础上学习 B 和 A 的权重, 即可使预训练模型适配不同任务, 从而显著提升 Stable Diffusion 模型微调的计算效率, 同时确保在特定数据集或任务上获得最优性能。

2 实验设计

文中基于 Stable Diffusion 模型, 结合 LoRA 微调技术实现服装款式图的生成。通过 Python 编程构建完整的模型架构, 确保实验流程的有效进行, 具体实验流程如图 4 所示。具体流程如下:

- 1) 环境部署: 本地部署, 下载预训练模型及外挂模型, 根据特定的绘画任务, 适应性更改和调整选定模型的结构和参数。
- 2) 数据准备: 为微调模型准备特定任务的数据集, 需要收集与款式图相关的图像数据并进行标记和清理。
- 3) 微调模型训练: 导入准备完毕的数据集, 加载参数对微调模型进行训练, 此过程中通常会使用较小的学习率, 以平衡预训练模型的知识和新任务数据的影响。
- 4) 评估和调整: 对微调模型进行评估, 并根据需要进一步调整和优化模型权重。
- 5) 嵌入与生成: 将训练成功的模型嵌入 Stable Diffusion 进行结果验收。




图4 实验流程设计
Fig.4 Experimental process design

3 智能衬衫款式生成训练

3.1 训练前准备

3.1.1 搭建环境 为确保实验顺利开展,需预先配置算法运行的基础环境。实验采用基于 Windows 10 专业版系统的硬件平台,配置 Intel i7-9700 处理器、NVIDIA RTX 2060 (8GB 显存) 显卡及 16GB 内存。软件环境搭建采用 Python 3.10.8 作为基础编程语言,结合 PyTorch 深度学习框架,并集成 tensorboardX 等可视化工具,构建完整的深度学习训练平台。

3.1.2 本地环境部署与参数预设 首先完成Stable Diffusion 的本地环境部署,随后进行预训练模型的选择。文中采用 anything-v5-PrtRE 作为基础模型,并搭配 animevae.pt 作为外接 VAE 模型。这些模型已在大规模图像数据集上完成预训练,通过图像分类、目标检测等多类视觉任务的优化,具备优异的特征表征能力。

3.1.3 实验数据集 如同设计专业学生通过临摹掌握款式图绘制技法,AI 模型同样需要基于专业的款式图数据集进行学习训练。文中采用 LoRA 微调技术,仅需少量的训练样本即可取得理想效果^[14]。实验样本来源包括服装设计专业学生手绘的款式图作品,以及行业主流商用平台的开放图片资源。选择衬衫作为样本的原因在于衬衫是服装设计中最基础且变化多样的品类之一,它包含了众多设计元素(如领型、袖型和纽扣等),可以为模型提供丰富的学习案例;此外衬衫的设计风格广泛,从休闲到正式场合都有应用,有助于增强模型对不同风格和用途的理解与生成能力。高质量的衬衫款式图需满足以下条件:①在结构准确性方面,款式图需要准确呈现出衬衫的立体剪裁结构,并标注各设计细节的尺寸比例与空间关系;②在制图规范性上,严格遵循行业标准,符合人体工学比例要求,采用标准化绘图符号与标注方式,以确保款式图的准确性和可操作性;③在细节完整性方面,要求包含领型、袖型、门襟等关键部件,清晰表现缝线、省道等工艺细节,并准确绘制纽扣、口袋等装饰元素;④在美观性方面,款式图需构图均衡、线条流畅,符合当下市场需求。

部分款式图数据集如图 5 所示。文中构建的衬衫款式图数据集严格遵循上述专业标准,如多样化领型设计,包括标准领、翻领、立领等典型结构;完整袖型系列,含长袖、短袖及三分袖等季节性款式;多元化剪裁版型,如修身、宽松及收腰等不同廓形

设计[见图 5(a)]。该数据集共收录 100 张专业级衬衫款式图,全面覆盖衬衫产品的核心设计要素,为模型训练提供了丰富的特征样本。对无法直接使用的素材进行图像分类和数据预处理,包括人工筛选(删除低像素图片)、清洁数据(背景处理成白色只保留具有合适构图的图像)、裁剪后的图片像素为 512 × 512。最后采用 WD1.4 标签器(tagger)反推标签,对反推出的标签进行人工干预修改,获得最终的图文数据集[见图 5(b)]。通过以上数据清理和标记步骤,能让模型更精准理解并学习任务所需的特定绘画特征。



图 5 部分款式图数据集

Fig. 5 Garment style diagram samples

3.2 训练参数调整

3.2.1 微调模型训练 将原始预训练模型的参数加载到微调模型中,并根据任务和数据集对相关参数进行初始化,选择初始模型的底模路径(即预训练模型权重文件的存储位置)。将预处理完成的训练图集和标签文本数据存放于训练目录文件夹中,并对文中数据模型进行生成训练,设置参数并在主

函数下运行程序,具体如图 6 所示。

```
pretrained_model_name_or_path = "/sd-models/anything-v5-PrtRE"
train_data_dir = "./train/aki"
resolution = "512,512"
enable_bucket = true
min_bucket_reso = 256
max_bucket_reso = 1_024
output_name = "drill"
output_dir = "./output"
save_model_as = "safetensors"
save_every_n_epochs = 2
max_train_epochs = 10
train_batch_size = 1
network_train_unet_only = false
network_train_text_encoder_only = false
learning_rate = 0.0001
unet_lr = 0.0001
text_encoder_lr = 0.00001
lr_scheduler = "cosine_with_restarts"
optimizer_type = "AdamW8bit"
lr_scheduler_num_cycles = 1
network_module = "networks.lora"
network_dim = 32
network_alpha = 32
logging_dir = "./logs"
caption_extension = ".txt"
shuffle_caption = true
keep_tokens = 0
max_token_length = 255
seed = 1_337
prior_loss_weight = 1
clip_skip = 2
mixed_precision = "fp16"
save_precision = "fp16"
xformers = true
cache_latents = true
persistent_data_loader_workers = true
lr_warmup_steps = 0
```

图 6 训练参数预览

Fig.6 Preview of training parameters

3.2.2 调整模型权重 完成微调模型训练后,将微调后的模型参数整合至底模型,并根据需要进行调整和优化,包括对微调模型 LoRA 适配权重的系统评估,具体见表 1。

表 1 不同 LoRA 权重对生成结果的影响

Tab.1 Impact of different LoRA weights on the generation results

权重	生成图像	分析
0~0.2		权重值过低,模型在生成图像时无法充分利用原始模型知识
0.3~0.5		生成结果容易受到随机噪音的干扰,无法保持原始模型稳定性
0.6~0.8		原始模型和新增权重较为平衡,能更好地呈现特定风格特征
0.9~1.0		新增权重值过大,知识发生冲突,部分结果偏离原始模型


当权重值在 0.5 时,LoRA 对原始模型的影响相对较弱,模型在生成图像时无法充分利用原始模型所学到的知识,且生成结果受随机噪音的干扰,无法保持原始模型的稳定性。当权重值在 0.91.0 范围时,新增权重会过度强化,在生成图像时可能和原始模型的知识发生冲突,部分生成结果偏离原始模型。当权重值在 0.60.8 范围时,原始模型和新增权重之间的关系更加平衡,且对服装款式图像的风格特征把握更加精准。

3.3 实验结果评估

将微调前后生成图像集进行对比,如图 7 所示。在保持相同基础模型 (Stable Diffusion 模型为 anything-v5-PrtRE)、参数设置 (CLIP 终止层数为 2,迭代步数为 20,采样方法为 Euler) 和输入关键词 (a log-sleeved shirt, Putfed sleeves 等) 的条件下,原始底模生成的图像缺乏专业款式图的特征表现;而嵌入微调 LoRA 模型后,生成图像的专业性与完成度显著提升,其细节表现与设计师手绘款式图具有更高的相似度。为全面评估模型性能,文中采用主客观相结合的评价方法对模型生成效果进行系统分析。



(a) 原始底模生成图像



(b) 嵌入微调模型生成图像

图 7 微调前后生成图像集对比

Fig.7 Comparison of generated images before and after fine-tuning

在客观评价方面,实验选择结构相似性算法



(structural similarity index metric ,SSIM) 和峰值信噪比(peak signal to noise ration, PSNR)对生成图像进行评价^[15-16]。其中,SSIM 算法主要从亮度、对比度、结构等方面来评估两幅图片间结构的差异性;SSIM 的范围为 01,其得分越接近 1 表示生成图像与原有图像差异性越小。PSNR 是用来评价噪声水平或图像失真的客观评价指标,PSNR 越大说明失真越少,生成图像的质量越好。将 100 张原始底膜生成图像与 100 张原始数据集编组为样本 1,将 100 张微调后的数据集和原始数据集编组为样本 2 输入算法,具体见表 2。由表 2 可以看出,微调后的模型在 SSIM 和 PSNR 指标上分别提升了 22. 69% 和 68. 59%。由此可知,微调训练后的图像与原数据差异更小,生成的图像质量更高。

表 2 实验结果客观评价

Tab. 2 Objective evaluation of experimental results		
样本编号	平均 SSIM	平均 PSNR
1 [#]	0. 736	6. 639
2 [#]	0. 903	11. 193

在主观评价方面,采取小组讨论结合专家访谈进行实验评价。并采用相同模型、参数和关键词进

表 3 原始生成图像与微调后生成图像对比评估

Tab. 3 Comparison evaluation of images before and after fine-tuning				
评价指标	未嵌入LoRA的生成效果	评价	嵌入LoRA的生成效果	评价
结构		生成结构有误		结构较为准确
构图		构图存在偏差		构图分布合理
风格		厚涂板绘风格		平面结构图风格
细节		细节粗糙简陋		细节相对丰富
线条		未见明显线条		线条清晰流畅

行对比测试,发现嵌入 LoRA 模型和未嵌入 LoRA 模型的图像会产生不同效果,具体而言,使用 LoRA 模型优化后,模型生成的图像在细节表现和风格一致性上有显著提升,而未使用 LoRA 优化时,生成的图像在某些细节上可能不够精准或风格不够统一,由此进一步验证了使用 LoRA 模型可生成高质量图像。组织服装设计专业的学生进行智能生成图像结果讨论,深入分析生成图像的质量特征;通过深度访谈收集资深设计师的专业评价,从结构、构图、风格、细节、线条 5 个指标对生成的图像进行对比评定(见表 3),从而分析图像的整体质量、视觉吸引力和内容的准确性。在结构方面,LoRA 微调后的模型有效改善了基础模型常见的比例失调和布局紊乱问题,使物体空间关系更加合理。构图指标方面,LoRA 改进后的模型有效纠正了原始模型产生的倾斜构图现象,使生成的图像在物体排布和整体布局上更符合视觉美学准则。风格指标方面,LoRA 增强后的模型能更好地保留源数据集的风格特征。细节指标方面,LoRA 微调后的模型在线条清晰度和细节丰富度上均有显著提升,证明其具备稳定的风格输出能力,可满足工业化批量生成的需求。

4 结 语

服装款式图作为服饰设计的关键载体,在传达设计理念、指导样衣制作和生产流程中发挥着不可替代的作用。文中以衬衫设计为切入点,基于Stable Diffusion 框架,采用 LoRA 微调技术实现了 AI 辅助的快速图像生成。实验结果表明,优化后模型的 SSIM 和 PSNR 指标分别提升了 22.69% 和 68.59%,验证了该方法的有效性。同时,通过结构、构图、风格等维度的系统评估,证实微调模型在生成稳定性与服装设计适配性方面均有显著提升。

目前,由于受技术限制,主流服装款式图多为矢量格式,而 Stable Diffusion 目前仅支持 JPG 位图生成。因此,在未来研究工作中,笔者将持续扩充训练数据集,逐步实现多品类服装图像的精准可控生成。值得关注的是,随着 AI 绘画工具如 Midjourney 已成功集成矢量图生成插件,这一技术障碍有望在 Stable Diffusion 平台得到突破。

参考文献:

[1] 吴琼. 人工智能时代的创新设计思维[J]. 装饰, 2019(11): 18-21.
WU Qiong. Innovative design thinking in the era of artificial intelligence[J]. Zhuangshi, 2019(11): 18-21. (in Chinese)

[2] 詹希旎, 李白杨, 孙建军. 数智融合环境下 AIGC 的场景化应用与发展机遇[J]. 图书情报知识, 2023, 40(1): 75-85, 55.
ZHAN Xini, LI Baiyang, SUN Jianjun. Application scenarios and development opportunities of AIGC in the digital intelligence integration environment[J]. Documentation, Information and Knowledge, 2023, 40(1): 75-85, 55. (in Chinese)

[3] 周楚轶, 柴春雷, 杨程. 人工智能辅助设计迭代研究——以平面设计为例[J]. 包装工程, 2021, 42(18): 50-62.
ZHOU Chuyi, CHAI Chunlei, YANG Cheng. Artificial intelligence augmented design iteration support: take graphic design for example[J]. Packaging Engineering, 2021, 42(18): 50-62. (in Chinese)

[4] WU J J, ZHANG C K, XUE T F et al. Learning a probabilistic latent space of object shapes via 3D generative-adversarial modeling [J]. Advances in neural information processing systems, 2016: 29.

[5] ALMAHAIRI A, RAJESHWAR S, SORDONI A, et al. Augmented CycleGAN: Learning many-to-many mappings from unpaired

data[C]//Proceedings of the 35th International Conference on Machine Learning (ICML). Stockholm:PMLR, 2018: 195-204.

[6] 李敏, 刘冰清, 彭庆龙等. 基于 CycleGAN 算法的迷彩服装图案设计方法研究[J]. 丝绸, 2022, 59(8): 100-106.
LI Min, LIU Bingqing, PENG Qinglong, et al. A camouflage suit pattern design based on the CycleGAN algorithm [J]. Journal of Silk, 2022, 59(8): 100-106. (in Chinese)

[7] 贾静, 曹竞文, 徐平华, 等. 基于京剧脸谱意象色彩的服饰纹样自动配色[J]. 纺织学报, 2022, 43(12): 160-166.
JIA Jing, CAO Jingwen, XU Pinghua, et al. Automatic coloration of clothing pattern based on color parsing of Peking Opera masks [J]. Journal of Textile Research, 2022, 43(12): 160-166. (in Chinese)

[8] TANG H, GENG G H, ZHOU M Q. Application of digital processing in relic image restoration design [J]. Sensing and Imaging, 2020(21): 6.

[9] HO J, JAIN A, ABBEEL P. Denoising diffusion probabilistic models[J]. Advances in neural information processing systems, 2020, 33: 6840-6851.

[10] KARAGOZ H F, BAYKAL G, EKSI I A, et al. Textile Pattern Generation Using Diffusion Models [J]. ArXiv Preprint Server, 2023: 2304.

[11] ROMBACH R, BLATTMANN A, LORENZ D, et al. High-resolution image synthesis with latent diffusion models[C]//2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). New Orleans: IEEE, 2022: 10674-10685.

[12] ZHANG Q, CHEN M, BUKHARIN A, et al. Adaptive budget allocation for parameter-efficient fine-tuning [J]. ArXiv Preprint Server, 2023: 10512.

[13] HU E J, SHEN Y, WALLIS P, et al. Lora: Low-rank adaptation of large language models[J]. ArXiv Preprint Server, 2021: 2106.

[14] HE J, ZHOU C, MA X, et al. Towards a unified view of parameter-efficient transfer learning [J]. ArXiv Preprint Server, 2021: 211.

[15] 肖红梅, 王伟珍, 房媛. 基于生成对抗网络的女上装图像属性编辑[J]. 服装学报, 2024, 9(1): 42-47.
XIAO Hongmei, WANG Weizhen, FANG Yuan. Image attribute editing of women's tops based on generating adversarial networks [J]. Journal of Clothing Research, 2024, 9(1): 42-47. (in Chinese)

[16] 陈雨琪, 薛涛, 刘俊华. 基于边缘增强和关联损失的服装图像风格迁移[J]. 现代纺织技术, 2024, 32(8): 117-126.
CHEN Yuqi, XUE Tao, LIU Junhua. Clothing pattern style transfer based on edge enhancement and association loss [J]. Advanced Textile Technology, 2024, 32(8): 117-126. (in Chinese)

(责任编辑:张 雪)