光电技术及应用

DOI：10.16818/j.issn1001－5868.20250408001

基于LDDC-GAN的丁基橡胶数据生成模型研究

耿家锴，闫　莉*，李雨菲，王　丹
（西安工业大学 机电工程学院，西安 710021）

摘　要： 针对工业视觉检测中丁基橡胶样本稀缺、现有生成模型在小样本下易崩溃及属性失真问题，文章提出一种轻量化双域约束生成对抗网络（LDDC-GAN）。该模型引入频域能量对齐机制以抑制模式崩溃，并结合余弦损失对纹理特征进行约束，通过频域与空间域的协同优化，保证生成图像在结构上的连续性和细节的真实性；同时，设计了渐进式通道压缩策略，将模型参数量降低至4.42 M，显存占用优化至6.4 GB，并融合改进的StyleGAN2生成器、判别器架构与动态梯度裁剪策略，在386张256×256工业样本上实现了高效收敛。实验结果表明，该模型在FID和SSIM指标上均优于当前主流基线模型。

关键词： 生成对抗网络；频域约束；纹理特征对齐；渐进式通道压缩；数据增强
中图分类号： TP183　**文章编号：** 1001－5868(2025)04－0705－07

Butyl Rubber Data Augmentation Algorithm Based on Lightweight Dual-Domain Constrained Generative Adversarial Network

GENG Jiakai, YAN Li, LI Yufei, WANG Dan
(**School of Mechatronic Engineering, Xi'an Technological University, Xi'an 710021, CHN**)

Abstract: A lightweight dual-domain constrained generative adversarial network (LDDC-GAN) is proposed to address the limited availability of butyl rubber samples for industrial visual inspection, as well as issues of mode collapse and attribute distortion in existing generative models under small-sample conditions. This model introduces a frequency-domain energy alignment mechanism to suppress mode collapse and incorporates cosine loss to constrain texture features. By jointly optimizing the frequency and spatial domains, the model ensures structural continuity and realistic details in the generated images. In addition, a progressive channel compression strategy is designed to reduce the model size to 4.42 M parameters and optimize memory usage to 6.4 GB. Combined with an improved StyleGAN2-based generator, discriminator architecture, and a dynamic gradient clipping strategy, the model efficiently converged on a dataset of 386 industrial samples of resolution 256×256. The experimental results demonstrate that the proposed model achieved better performance than the current mainstream baseline models, as measured by the FID and SSIM metrics.

Key words: generative adversarial network; frequency domain constraint; texture feature alignment; progressive channel compression; data augmentation

0　引言

工业视觉检测系统的可靠性直接关联数据集与目标材料特性的匹配度。现有通用工业数据集（如MVTecAD）涵盖多类材质，但其设计逻辑与丁

收稿日期：2025－04－08.
基金项目：陕西省秦创原“科学家＋工程师”队伍建设项目（2025QCY-KXJ-048）.
*通信作者：闫　莉

基橡胶等材料的检测需求存在差异，导致性能受限。核心矛盾在于，通用数据集的典型纹理特征（金属划痕方向性、织物纤维结构）难以表征橡胶材料的粘弹性形变与微观分布特性。在无监督缺陷检测场景中，模型需从有限正常样本中学习材料本征特征，而工业采集条件常导致样本多样性不足，制约模型鲁棒性。生成模型虽具备缓解数据稀缺的潜力，但现有方法仍面临显著技术瓶颈。

近年来，生成对抗网络（GAN）在工业检测中的应用逐渐扩大，涵盖缺陷检测、异常定位、图像质量增强以及数据增强等领域。例如，Schlegl等[1]提出的AnoGAN通过潜在空间映射精准定位半导体晶圆缺陷，而Hasan等[2]的ST-GAN通过时空注意力机制提升机械臂运动异常检测性能，曲线下面积（Area Under the Curve，AUC）达98.2%。此外，GAN还被用于提升工业图像质量，如Zhu等[3]开发的CycleGAN在无配对数据条件下增强X光图像的辨识度峰值信噪比（Peak Signal-to-Noise Ratio，PSNR）提升18%。然而，GAN在工业缺陷合成方面仍面临诸多挑战，例如基于DCGAN改进的方法在小样本条件下难以生成高质量样本，而StyleGAN2[4]适应于解决大样本条件下的数据生成，在小样本（300～500）条件下无法收敛。

针对小样本数据问题，研究者提出了多种数据生成策略。迁移学习方法（如TransferGAN[5]）通过冻结部分预训练参数适应新任务，但对数据分布变化较为敏感，而DAGAN[6]通过领域适配对齐合成与真实数据分布，虽然提高了生成质量，但计算成本较高。隐空间解耦生成方法增强了潜在空间的多样性，但小样本训练的稳定性仍面临挑战。此外，仿真融合生成（如SimGAN[7]）利用物理建模引导数据合成，但对材质参数依赖较强，难以满足工业需求。DatasetGAN[8]充分利用生成器潜空间的语义一致性，通过极少量图像的像素级标注，训练逐像素分类器实现自动标签生成，显著降低了大规模标注成本；但该方法依赖高精度的初始人工分割标注，相比其他无需标注的生成模型仍存在人为参与门槛高、准备流程复杂等问题，难以在无先验标签的任务中直接部署。

另一方面，频域和纹理约束技术在提升生成图像质量方面取得了一定进展。例如，Roy等[9]提出基于FFT频谱能量约束的方法，在金属表面缺陷重建中提高了频域一致性（PSNR提升2.1 dB），但未结合空间域优化，导致高频区域伪影增加（SSIM下降0.15）。红-黑小波变换策略[10]虽然能降低噪声干扰，但其频域权重依赖人工经验调整，难以适应动态工业场景。此外，Johnson等[11]提出的VGG感知损失能够提取高层语义特征，在橡胶表面纹理对齐任务中取得较高的余弦相似度。然而，该方法对非均匀光照环境敏感度较低，而局部纹理约束方法[12]虽在提升超分辨率细节生成方面表现良好，但手工设计的LBP特征描述符难以泛化至多种工业材质，限制了其应用范围。

针对上述问题，本文构建丁基橡胶专用工业数据集（386张无缺陷样本，256×256分辨率），并提出双域联合优化的轻量化生成对抗网络（LDDC-GAN）。该框架通过频域—空间域协同约束机制，在保持材料物理属性的同时实现高效小样本训练，有效地改善了工业检测中数据有限与生成质量失衡的问题。

1 LDDC-GAN模型

所提出的轻量化双域约束生成对抗网络模型LDDC-GAN，针对工业检测中小样本条件下图像增强任务，整体框架包含生成器、判别器与动态训练策略三个核心模块，其理论创新体现为双域损失函数设计、参数效率优化及稳定性控制机制。网络结构如图1所示。

1.1 整体架构设计

生成器G以潜在向量$z\in\mathbb{R}^{100}$为输入，通过多层级联的残差风格块生成目标图像。其目标函数融合空间域对抗损失与频域能量约束，空间域对抗损失捕捉像素级分布特性，频域约束强化图像结构的内在连续性：

$$\mathcal{L}_G=\mathbb{E}_z\{-D[\boldsymbol{G}(z)]\}+\lambda_t\mathcal{L}_{\text{tex}}[\boldsymbol{G}(z),\boldsymbol{x}_{\text{real}}]+\lambda_f\mathcal{L}_{\text{feq}}[\boldsymbol{G}(z),\boldsymbol{x}_{\text{real}}] \tag{1}$$

判别器D的优化目标包含Wasserstein距离度量与梯度惩罚项：

$$\mathcal{L}_D=\mathbb{E}_{x_{real}}[-\boldsymbol{D}(\boldsymbol{x}_{\text{real}})]+\mathbb{E}_z[D(\boldsymbol{G}(z))]+\gamma\mathbb{E}_{\hat{x}}\left\{\left[\|\nabla_{\hat{x}}\boldsymbol{D}(\hat{\boldsymbol{x}})\|_2-1\right]^2\right\} \tag{2}$$

1.2 双域约束生成器设计

1.2.1 残差式风格调制模块

生成器主体由原StyleGAN2的18层减为5层，每一层使用独特级联残差风格块（Res-StyleBlock）

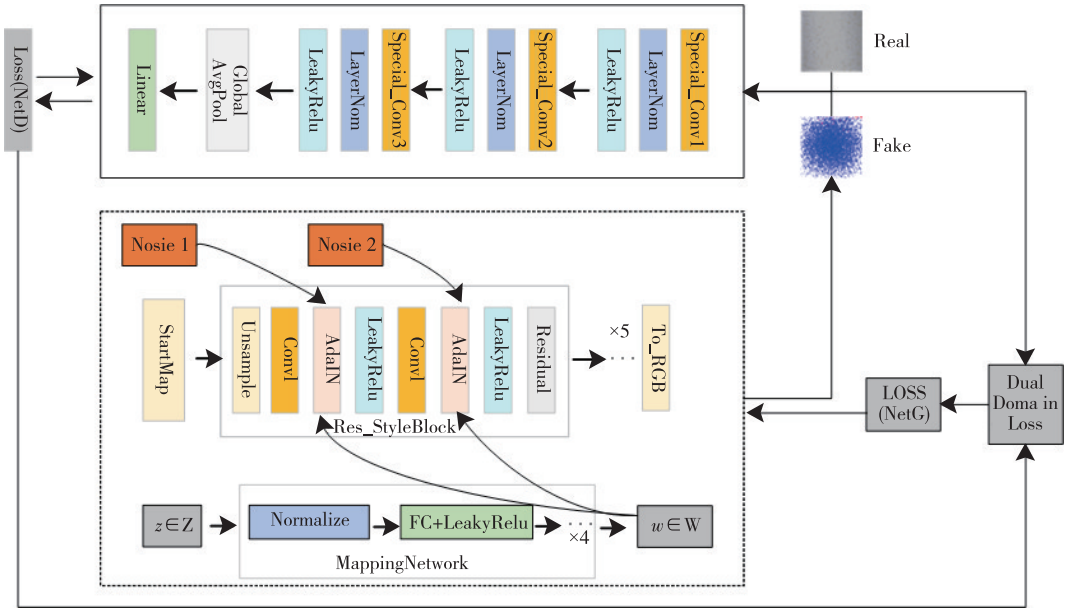


图1　LDDC-GAN模型架构

构成，在原级联结构基础上增加残差连接，残差连接的恒等分量保留原始特征分布，防止生器过度拟合有限样本，其数学表达为：

$$\boldsymbol{h}_l=\mathcal{F}_l(\boldsymbol{h}_{l-1})+\mathcal{T}(\boldsymbol{h}_{l-1}) \tag{3}$$

式中，$\mathcal{F}_l$为主路径运算，$\mathcal{T}$为残差路径的通道适配函数。通过精简层数与权值共享策略，在保证生成质量的前提下，提升推理速度并减少显存占用。

选用自适应实例归一化AdaIN[13]，不采用StyleGAN2的权重解调是由于本文采用丁基橡胶作为训练样本，该样本集中于高频纹理特征，而AdaIN在特征图层面的操作能更好保持高频纹理，且权重解调容易在小样本训练下导致模式崩溃。给定风格向量$\boldsymbol{s}\in\mathbb{R}^{512}$，特征图$\boldsymbol{x}\in\mathbb{R}^{C\times H\times W}$的调制过程为：

$$AdaIN(\boldsymbol{x},\boldsymbol{s})=\gamma(\boldsymbol{s})\cdot\frac{\boldsymbol{x}-\boldsymbol{\mu}(\boldsymbol{x})}{\boldsymbol{\sigma}(\boldsymbol{x})}+\beta(\boldsymbol{s}) \tag{4}$$

在双线性上采样后注入可学习权重的噪声：

$$\boldsymbol{x}'=\boldsymbol{x}+\boldsymbol{\alpha}\odot\boldsymbol{n},\boldsymbol{n}\sim\mathcal{N}(0,I) \tag{5}$$

式中，$\alpha\in\mathbb{R}$为可训练参数，通过反向传播自适应调节噪音强度。

2.2.2　双域约束模块

定义频域一致性损失函数：

$$\mathcal{L}_{freq}=\frac{1}{HW}\sum_{u,v}\Delta\mathcal{F}_{u,v}^2 \tag{6}$$

$$\Delta\mathcal{F}_{u,v}=\left|\mathcal{F}\left[G(\boldsymbol{z})\right]_{u,v}\right|-\left|\mathcal{F}(\boldsymbol{x}_{\text{real}})_{u,v}\right| \tag{7}$$

强制生成图像与真实样本在频域能量分布上对齐，避免因空间域逐像素优化导致的局部伪影。传统仅依赖VGG感知损失的方法易忽略低频结构信息（如材质均匀性），而频域约束通过全局频谱能量匹配，保证生成图像在整体光照、纹理连续性上符合物理规律。同时，VGG感知损失通过预训练网络的高层特征（ϕVGG）捕获语义级纹理相似性：

$$\mathcal{L}_{tex}=\|\phi_{VGG}\left[G(\boldsymbol{z})\right]-\phi VGG(\boldsymbol{x}_{\text{real}})\|_2^2 \tag{8}$$

1.3　纹理感知判别器设计

判别器采用谱归一化卷积层与层级归一化结合的轻量化结构：

$$f_D(x)=MLP\left\{\mathbb{E}_{h,w}\left\{\phi_3\left\{\phi_2\left[\phi_1(\boldsymbol{x})\right]\right\}\right\}\right\} \tag{9}$$

式中，ϕ_l表示第l层卷积运算，具体形式为：

$$\phi_l(\boldsymbol{x})=LN\left\{\sigma\left[SN(W_l*\boldsymbol{x})\right]\right\} \tag{10}$$

谱归一化通过约束权重矩阵的$Lipschitz$常数，防止判别器梯度爆炸：

$$W_{SN}=\frac{W}{\sigma_w} \tag{11}$$

$$\sigma_w=\max_{h\neq0}\frac{\|Wh\|_2}{\|h\|_2} \tag{12}$$

层级归一化则沿通道维度计算统计量，通过通道维度的均值方差归一化，抑制因样本不足导致的特征分布震荡，使判别器关注局部纹理差异而非整体亮度对比度变化：

$$LN(\boldsymbol{x})_{c,h,w}=\frac{\boldsymbol{x}_{c,h,w}-\boldsymbol{\mu}_c}{\sqrt{\boldsymbol{\sigma}_c^2+\epsilon}} \tag{13}$$

$$\mu_c = \frac{1}{HW}\sum_{h,w} x_{c,h,w} \tag{14}$$

判别器中同时采用谱归一化（约束权重矩阵谱范数）和层归一化（约束特征分布），形成双重稳定机制。

1.4 动态增强与训练策略

1.4.1 自适应数据增强

定义增强概率p_t随训练步数动态更新：

$$p_t = p_0 + \min\left(\frac{t}{T_{\text{steps}}}, 1\right)\left(p_{\text{target}} - p_0\right) \tag{15}$$

式中，t为当前训练步，T_{steps}为总过渡步数。增强操作包括：随机仿射变换，旋转角度$\theta \sim U_1$平移$\Delta x, \Delta y \sim U_2$；颜色抖动，亮度、对比度、饱和度在$U_3$区间随机调整。

1.4.2 混合精度训练

采用FP16/FP32混合精度加速训练，梯度缩放因子动态调整：

$$st+1 = \begin{cases} st \cdot \eta & \text{if } \exists \nabla \text{溢出} \\ st/\eta & \text{otherwise} \end{cases} \tag{16}$$

式中，η为缩放步长，通过监控梯度幅值自动调节缩放因子。

1.4.3 梯度裁剪策略

针对小样本训练中梯度幅值不稳定的问题，引入动态梯度裁剪机制。对生成器G和判别器D的梯度分别施加约束：

$$\|\nabla_{\theta_G}\mathcal{L}_G\|_2 \leqslant \tau_G \tag{17}$$

$$\|\nabla_{\theta_D}\mathcal{L}_D\|_2 \leqslant \tau_D \tag{18}$$

式中，τ_G和τ_D为经验阈值。该操作通过投影法将梯度限制在超球面内：

$$\nabla_{\text{clipped}} = \min\left(1, \frac{\tau}{\|\nabla\|_2}\right)\nabla \tag{19}$$

将原始梯度∇乘以比例因子，得到裁剪后的梯度∇_{clipped}，避免因个别样本的异常梯度破坏模型整体优化方向。

2 实验及结果分析

2.1 实验设置

本次实验的硬件与软件环境配置如表1所示。

表1 实验环境配置

名称	配置
操作系统	Window10专业版
CPU	Inteli9－13900K
GPU	RTX3090
CUDA	12.1
Python	3.9
Pytorch	2.6.0

实验研究的原始数据采集自X公司丁基橡胶六面检测系统，其核心目标是通过LDDC-GAN生成高质量假负样本，一方面与真实负样本联合训练，以提升无监督缺陷检测的鲁棒性；另一方面可以通过模型强大的生成能力尽快地泛化工业数据，提升系统部署效率。该轻量数据集由309张（80%）训练图片，以及77张（20%）测试图片构成，数据集仅含真实负样本，迫使生成模型仅学习正常纹理分布，数据集构建流程如图2所示。

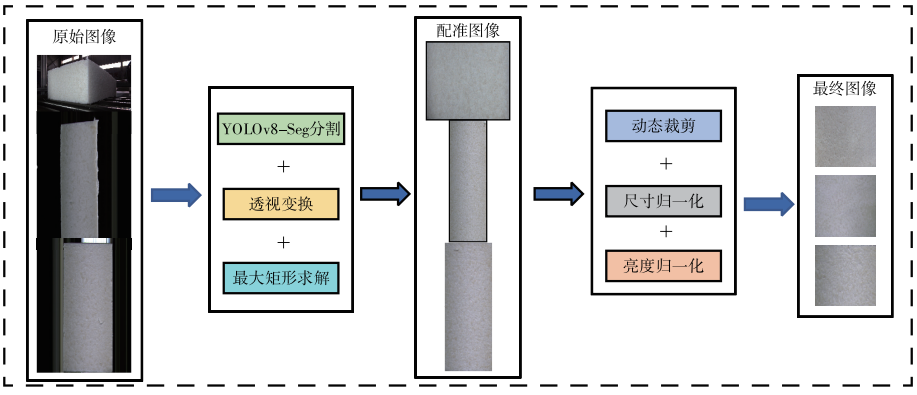


图2 数据集构建流程

首先使用YOLOv8-Seg进行目标分割，并通过单调栈法提取目标区域的最大内接矩形，随后采用透视变换进行校正。接着，对图像进行动态裁剪、尺寸归一化和亮度归一化，确保目标区域标准化，为后续模型提供高质量输入数据。

2.2 评估指标

为全面评估生成样本的质量及其与真实正常样本的分布一致性，从全局分布匹配与局部结构相

似性两个维度选取评估指标，各指标定义及选择依据如下：

FID基于Inception-v3特征空间的均值与协方差差异，量化生成数据集整体分布与真实数据的匹配程度，反映模型对数据多样性和全局统计规律的建模能力，通过比较特征空间中两个分布的统计特性（均值和协方差），计算其Wasserstein-2距离的平方近似值，反映生成样本与真实样本的全局分布匹配程度，避免了传统指标（如IS）对分类标签的依赖，直接衡量特征空间的分布相似性，更适合无监督生成任务中对正常样本分布建模的质量评估。计算公式：

$$FID=\left\|\boldsymbol{\mu}_r-\boldsymbol{\mu}_g\right\|^2+Tr\left(\sum\nolimits_r+\sum\nolimits_g-\sqrt{\sum\nolimits_r\sum\nolimits_g}\right) \tag{20}$$

式中，$\boldsymbol{\mu}_r$，$\boldsymbol{\mu}_g$分别代表真实样本集与生成样本集在Inception-v3网络特征空间的均值向量，$\sum_r$，$\sum_g$表示真实样本集与生成样本集的特征协方差矩阵，FID值越小，表示生成图像与真实图像之间的数据越接近，生成图像的质量越高。

SSIM作为模拟人类视觉感知机理的图像质量度量工具，通过量化生成样本与真实样本的局部像素关联性，评估纹理连续性及边缘锐度等高频细节的保真程度。其计算表达式为：

$$SSIM\left(x,y\right)=\frac{2\boldsymbol{\mu}_x\boldsymbol{\mu}_y+C_1}{\boldsymbol{\mu}_x^2+\boldsymbol{\mu}_y^2+C_1}\cdot\frac{2\boldsymbol{\sigma}_{xy}+C_2}{\boldsymbol{\sigma}_x^2+\boldsymbol{\sigma}_y^2+C_2} \tag{21}$$

该指数通过亮度感知（$\boldsymbol{\mu}_x$，$\boldsymbol{\mu}_y$）、对比度解析（$\boldsymbol{\sigma}_x$，$\boldsymbol{\sigma}_y$）及结构相关性（$\boldsymbol{\sigma}_{xy}$）三个维度构建评估体系，其值域为[0,1]。当数值趋近1时表征生成样本与真实样本在局部纹理模式及结构特征的匹配度最优。

2.3　结果分析

2.3.1　定量分析

为量化评估生成对抗网络模型在橡胶纹理合成任务中的性能表现，采用FID和SSIM两个指标进行定量评估，对比分析LDDC-GAN与主流模型（DCGAN[14]，EBGAN[15]，LSGAN[16]，WGAN-GP[17]和FastGAN[18]）的量化性能差异，实验结果如表2所示。

LDDC-GAN在两项指标上均显著优于主流基线模型，其*FID*（17.11）较最优模型FASTGAN（20.02）降低14.5%，*SSIM*（0.907 5）提升2.2%，表明该模型在纹理分布真实性与局部结构保真度上实现了更优的平衡。

表2　模型对比各指标分析结果

方法	评价指标	
	FID	*SSIM*
DCGAN	106.56	0.759 8
EBGAN	83.76	0.869 3
LSGAN	36.22	0.874 7
WGAN-GP	26.44	0.873 2
FastGAN	20.02	0.887 7
LDDC-GAN	17.11	0.907 5

2.3.2　定性分析

为进一步验证生成结果的视觉可信度，从纹理细节、颜色过渡和真实感三个维度对原始图像与各模型生成样本进行主观对比。LDDC-GAN在微观结构重建与色彩自然度方面展现出一定程度的优势，如图3所示。

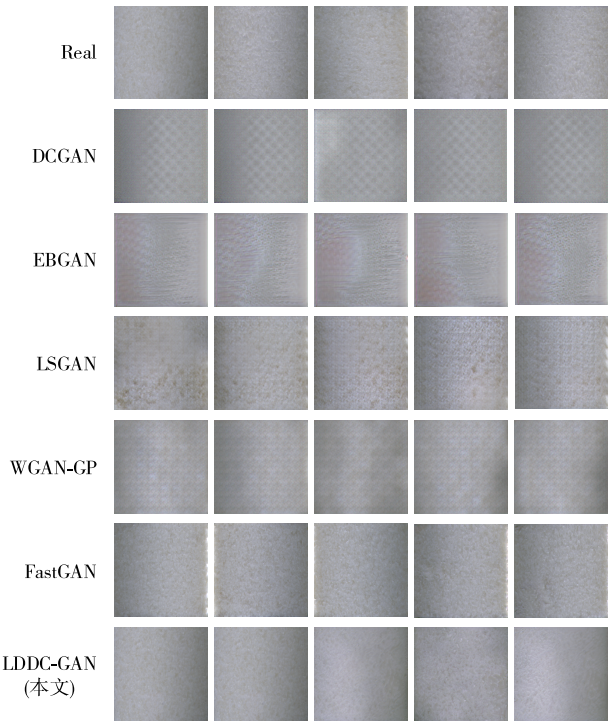


图3　模型对比定性分析结果

实验证明，基础模型DCGAN虽能重建主体结构，但存在纹理模糊与色彩断层现象；EBGAN由于能量模型的训练动态限制，生成纹理出现粗粒度特征聚合现象，细节分辨率显著降低；LSGAN通过最小二乘优化提升了轮廓清晰度，但引入人工规则的伪影；WGAN-GP凭借梯度惩罚机制使生成效果逼近原始分布，但在微观纹理层面上仍存在细节损失；针对小样本的FastGAN在轻量化结构中引入自监督判别器与跳跃层通道激励模块（SLE），在少样

本条件下实现稳定训练,其细节得到更好表征,但是其生成图像左右两侧仍存在边缘齿状缺陷以及过渡不平滑的问题。相比之下,所提出的LDDC-GAN通过创新的空频双域约束机制,在保持全局结构稳定性的同时,实现了细粒度纹理的精准建模。其生成结果不仅成功复现了原始图像中细微的材质特征,更通过自适应的颜色融合算法消除了传统方法中的过渡生硬问题,最终达到与原始图像近乎一致的视觉保真度,保证了生成图片的质量。

2.4 消融实验

实验通过渐进式模块消融,评估改进LDDC-GAN模型中关键组件对橡胶纹理生成质量的影响。对比分析残差连接、VGG约束、频域约束、谱归一化以及层归一化五个模块的独立贡献,实验在相同训练数据和超参数下进行。实验结果如表3所示。

表3 模块消融实验

方法	实验结果	
	FID	*SSIM*
w/o Residual	26.32	0.865 2
w/o Tex_loss	23.15	0.888 4
w/o Freq_loss	28.03	0.864 9
w/o Spectral_norm	26.19	0.863 1
w/o LayerNorm	31.26	0.848 3
LDDC-GAN	17.11	0.907 5

实验结果表明,LDDC-GAN各个模块对橡胶纹理生成质量具有独立贡献:完整模型(*FID*=17.11,*SSIM*=0.907 5)在五组对比中性能最优,其中频域约束(消融后*FID*上升64%)和层归一化(消融后*FID*上升82.9%)对生成稳定性影响最为显著。残差连接(*SSIM*下降4.6%)与谱归一化(消融后*FID*上升53%)在特征传递和梯度控制中发挥基础作用。值得注意的是,虽然层归一化消融模型在350轮次后出现模式崩塌,本文通过早选取了该配置下收敛最优的模型(*FID*=31.26),实验结果验证了多约束联合优化有效提升了生成模型的性能。

3 结论

针对工业视觉检测中高保真橡胶纹理样本不足和小样本生成模型难以收敛的问题,本研究构建基于双域联合约束的轻量化生成对抗网络(LDDC-GAN)。通过频域全局能量分布匹配机制与空间域深度特征相关性约束的协同优化,有效克服传统生成模型在低数据量场景中的模式崩溃与物理属性失稳问题。所提出的渐进式通道压缩架构结合动态梯度优化策略,显著降低模型复杂性与计算资源需求。实验结果表明,相较于标准生成框架,该方法在合成图像的边缘结构保真度及微观纹理连续性方面均展现出明显优势,验证了多约束联合优化机制在小样本工业纹理生成任务中的有效性。

参考文献:

[1] Schlegl T, Seeböck P, Waldstein S M, et al. F-AnoGAN: fast unsupervised anomaly detection with generative adversarial networks[J]. Medical Image Analysis, 2019, 54: 30-44.

[2] Lin C H, Yumer E, Wang O, et al. ST-GAN: spatial transformer generative adversarial networks for image compositing[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2018: 9455-9464.

[3] Zhu J Y, Park T, Isola P, et al. Unpaired image-to-image translation using cycle-consistent adversarial networks[C]//2017 IEEE International Conference on Computer Vision, 2017: 2242-2251.

[4] 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, 2020: 8107-8116.

[5] Wang Y, Wu C, Herranz L, et al. Transferring GANs: generating images from limited data[C]//Computer Vision - ECCV 2018, 2018: 220-236.

[6] Antoniou A, Storkey A, Edwards H. Data augmentation generative adversarial networks[J]. arXiv preprint arXiv:1711.04340, 2017.

[7] Shrivastava A, Pfister T, Tuzel O, et al. Learning from simulated and unsupervised images through adversarial training [C]//2017 IEEE Conference on Computer Vision and Pattern Recognition, 2017: 2242-2251.

[8] Zhang Y, Ling H, Gao J, et al. DatasetGAN: efficient labeled data factory with minimal human effort[C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 10140-10150.

[9] Roy H, Chaudhury S, Yamasaki T, et al. Image inpainting using frequency-domain priors [J]. Journal of Electronic Imaging, 2021, 30(2): 023016.

[10] 许廷发, 祁金刚, 周生兵, 等. 频域约束的红-黑小波变换图像复原算法[J]. 北京理工大学学报, 2007, 27(5): 446-450.
Xu Tingfa, Qi Jingang, Zhou Shengbing, et al. Frequency restricted red-black wavelet transform for image restoration [J]. Transactions of Beijing Institute of Technology, 2007, 27(5): 446-450.

[11] Johnson J, Alahi A, Li F F. Perceptual losses for real-time style transfer and super-resolution[C]//Computer Vision - ECCV 2016, 2016: 694-711.

[12] 王宝成，李　波．基于$L_{1/2}$正则化和局部纹理约束的人脸超分辨率图像重建[J]．计算机应用研究，2020，37(2)：598-600，605.
Wang Baocheng，Li Bo. Face image super-resolution *via* $L_{1/2}$ regularization and local texture constraints[J]. Application Research of Computers，2020，37(2)：598-600，605.

[13] Karras T，Laine S，Aila T. A style-based generator architecture for generative adversarial networks[C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition，2019：4396-4405.

[14] Kaselimi M，Voulodimos A，Protopapadakis E，et al. EnerGAN：a generative adversarial network for energy disaggregation[C]//ICASSP 2020 - 2020 IEEE International Conference on Acoustics，Speech and Signal Processing，2020：1578-1582.

[15] Mehralian M，Karasfi B. RDCGAN：unsupervised representation learning with regularized deep convolutional generative adversarial networks[C]//2018 9th Conference on Artificial Intelligence and Robotics and 2nd Asia-Pacific International Symposium，2018：31-38.

[16] Mao X，Li Q，Xie H，et al. Least squares generative adversarial networks [C]//2017 IEEE International Conference on Computer Vision，2017：2813-2821.

[17] Gulrajani I，Ahmed F，Arjovsky M，et al. Improved training of wasserstein gans[C]// NIPS′17：Proceedings of the 31st International Conference on Neural Information Processing Systems，2017：5769-5779.

[18] Liu B，Zhu Y，Song K，et al. Towards faster and stabilized GAN training for high-fidelity few-shot image synthesis[C]// International Conference on Learning Representations，2021：1-13.

作者简介：

耿家锴(2000—)，男，山西省阳泉市人，硕士研究生，主要从事图像生成、工业无监督缺陷检测算法研究；

闫　莉(1973—)，女，安徽省亳州市人，博士，教授，博士生导师，主要从事机器视觉、智能检测与质量控制相关研究。