利用深度学习恢复光学相干断层扫描图像的光谱带宽

TIMOTHY T. YU1,4、DA MA[2,1]*、JAYDEN COLE1、MYEONG JIN JU3,4、MIRZA F. BEG1 和 MARINKO V. SARUNIC[1,5,6]*

[1]工程科学系，西蒙弗雷泽大学，加拿大不列颠哥伦比亚省本拿比，V5A1S6[2]维克森林大学医学院，美国北卡罗来纳州温斯顿-塞勒姆，27151[3]眼科与视觉科学系，英属哥伦比亚大学，加拿大不列颠哥伦比亚省温哥华，V5Z 3N9[4]生物医学工程学院，英属哥伦比亚大学，加拿大不列颠哥伦比亚省温哥华，V5Z 3N9[5]生物医学工程学院，英属哥伦比亚大学，加拿大不列颠哥伦比亚省温哥华，V5Z 3N9[5]眼科研究所，伦敦大学学院，英国伦敦[6]医学物理与生物医学工程系，伦敦大学学院，英国

dma@wakehealth.edu
m.sarunic@ucl.ac.uk

1. 摘要 光学相干断层扫描

（OCT）可获取横截面数据，常用于视网膜疾病的筛查、监测和治疗规划。为提高采集速度而进行的技术改进，往往会使系统的光谱带宽变窄，进而降低轴向分辨率。传统上，人们采用基于图像处理的技术重建子采样OCT数据，近年来也开始探索基于深度学习的方法。本研究通过在光谱域进行高斯加窗，模拟降低轴向扫描（A 扫描）分辨率，并探究基于学习的方法在图像特征重建中的应用。考虑到宽视场OCT系统所伴随的分辨率降低，我们以超分辨率技术为基础，探索如何更好地辅助临床医生进行决策、改善患者预后：通过采用经过改进的超分辨率生成对抗网络（SRGAN）架构，利用像素到像素方法重建丢失的特征。

2. 引言

光学相干断层扫描（OCT）是一种非侵入性成像模态，可对视网膜进行高分辨率的体积成像。视网膜是位于眼球后部、对光敏感的组织。OCT 是诊断年龄相关性黄斑变性（AMD）和糖尿病性黄斑水肿（DME）等疾病的金标准，但由于视野（FOV）有限，目前尚未被广泛接受用于糖尿病视网膜病变（DR）的诊断和监测 [1]。OCT 有助于表征视网膜厚度变化及异常，这些变化和异常是 DR 的指征；若将 OCT 作为辅助诊断模态，可能有助于改善 DR 患者的预后。我们此前已证明，中心凹旁区以外的血管系统中存在可反映 DR 早期变化的特征 [2]。因此，相关技术正朝着开发广域 OCT 系统的方向发展，以捕捉更多视网膜细节。

随着 OCT 硬件技术不断进步，视网膜成像的视野越来越广，同时也在努力减少因视野增大、采集时间延长而常伴随的运动伪影和患者不适。提高采集系统的速度往往需要在工程设计上做出妥协，从而降低 OCT 系统的光谱带宽，进而降低轴向分辨率。拼接成像 [3] 和运动跟踪软件 [4] 等方法，都是为减轻广域 OCT 系统带来的不利影响而探索的技术。此外，研究人员还探索了利用机器学习重建 OCT血管成像（OCTA）的特征，以提高其临床应用所需的图像质量 [5]。

在本研究中，我们模拟了 OCT 体数据中较窄的光谱带宽，并探讨了生成对抗网络（GAN）的应用。对于图像到图像生成，许多实现采用像素到像素（pix2pix）GAN，其生成器中包含编码器/解码器。我们采用 pix2pix 方法，并利用改进的超分辨率生成对抗网络（SRGAN）[6]架构，在 OCT B 扫描中恢复高分辨率特征。SRGAN 由 VGG-19 风格判别器以及包含残差块和亚像素卷积层的生成器组成。针对我们的 pix2pix 实现，我们对 SRGAN 架构进行了改进：加深判别器和生成器，并移除了生成器中的像素上采样层。

受数据集规模限制，我们借助一个开源天然花卉数据集[7]进行迁移学习，并参考了类似的 SRGAN 方法，该方法曾用于提升射线图像的分辨率[8]，以促进深度神经网络（DNN）的收敛。花卉数据集包含不同花卉、花瓣和种子的复杂特征图像，其边缘密集且清晰。这些特征会加剧模糊过程，因此在用作 OCT 超分辨率生成对抗网络的初始化权重时可能会有所助益。

原始架构旨在放大图像，并重建因缩小图像而丢失的特征。我们不使用 OCT 超分辨率生成对抗网络从调整尺寸后的小图像重建更大的图像，而是研究通过迁移学习，利用 OCT 超分辨率生成对抗网络重建轴向上降低的光谱分辨率（A 扫描模糊），并展示基于学习的方法重建丢失特征的能力。我们的研究结果表明，如果与宽视场 OCT 系统并行开发，深度神经网络或可通过重建因光谱带宽变窄而丢失的特征，为临床医生提供帮助；更窄的光谱带宽往往伴随着 A 扫描线速率更快的 OCT 系统。我们的主要贡献是改造利用超分辨率生成对抗网络进行 OCT B扫描超分辨率处理的特征恢复方法。我们展示了初步结果，并将继续开发 OCT 超分辨率生成对抗网络，进而探索特征金字塔网络等其他基于学习的方法。如图 1 所述，本实验分两步进行：（1）使用包含 16 只眼睛的初步数据集，了解迁移学习的影响；（2）使用包含 35 只眼睛的完整数据集，比较在空间域与光谱域中进行重建的效果。

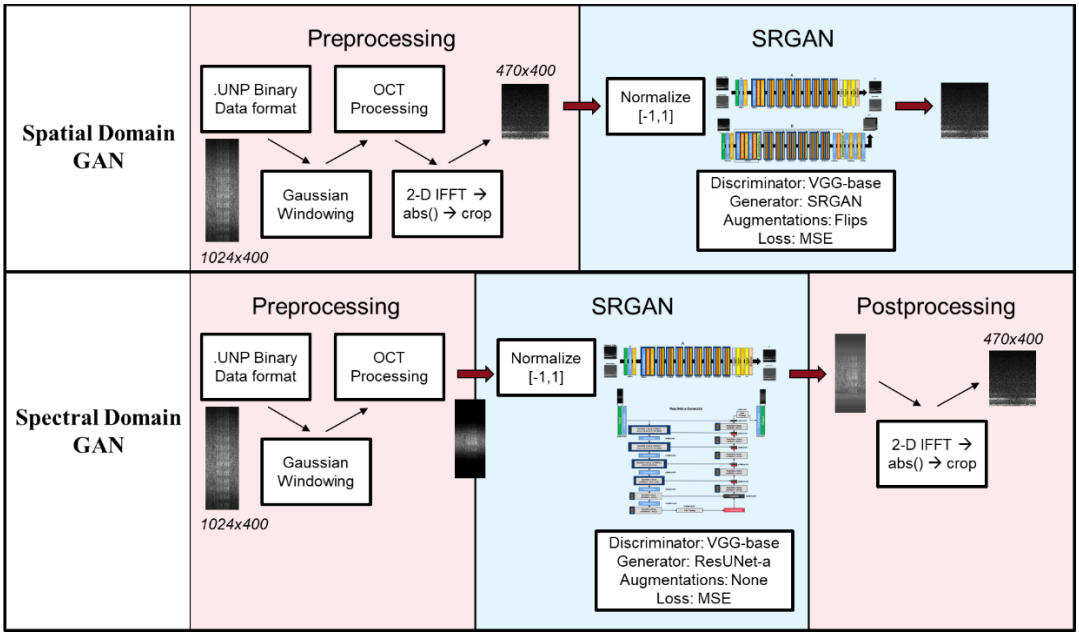


图 1 对比空间和光谱超分辨率生成对抗网络处理流程的并行示意图。

3. 方法

OCT 数据集及其准备

本研究纳入了27名不同患者的35只眼睛（包括病理性眼睛），每只眼睛均使用1060 nm扫频源 OCT 原型自适应光学系统，在以中央凹为中心的~2x2 mm FOV上成像。我们使用了可显示视网膜横截面的 B 扫描。该数据集的一个初始子集包含16只眼睛，最初用于验证从自然图像进行迁移学习的效果。在初步实验中，每幅 B 扫描均从1024x400裁剪为240x400（轴向x横向位置）；在第二个实验的空间域部分，则裁剪为470x400，并以每条包含20个 A扫描的条带形式进行处理。评估前，光谱域生成对抗网络所用图像的尺寸保持不变。由35只眼睛构成的完整数据集包含14,000个 B 扫描样本或5,600,000个独立的 A扫描样本。数据集分别按60%、20%、20%的比例划分为训练集、验证集和测试集。训练使用21只眼睛（8,400个 B 扫描或3,360,000个 A扫描），验证使用7只眼睛（2,800个 B 扫描或1,120,000个 A扫描），测试使用7只眼睛（2,800个 B 扫描或1,120,000个 A扫描）。相邻的 B 扫描包含相似信息。因此，每隔8个 B 扫描取用一个，以

确保采集之间有足够的间隔，从而尽可能降低模型对连续重复扫描过拟合的可能性。训练前，对训练集中的图像进行了随机打乱。我们特别注意确保同一患者的眼睛只用于训练、验证或测试中的其中一个环节。由于花卉图像是三通道 RGB图像，在使用花卉图像训练神经网络时，我们选取第一个通道，构成单通道输入，以模拟 OCT图像的领域。

OCT图像的轴向分辨率与光源的光谱特性有关。轴向分辨率的一种常用表达方式是相干长度 lc，其计算公式为 $l_c = \lambda_0^2/\Delta\lambda$，其中 λ_o 是中心波长，$\Delta\lambda$ 是光谱带宽。利用我们的扫频光源OCT原型系统，我们获得了波长域数据，并对光谱进行高斯加窗，从而降低了轴向分辨率。我们使用 MATLAB 函数 gausswin，并根据早期训练试验和 OCT B 扫描图像输出的外观选择了 $\alpha = 8,$ ；高斯窗（ w ）的系数如[1]所述。我们将此高斯加窗掩模与频域OCT数据逐元素相乘，如图2所示。

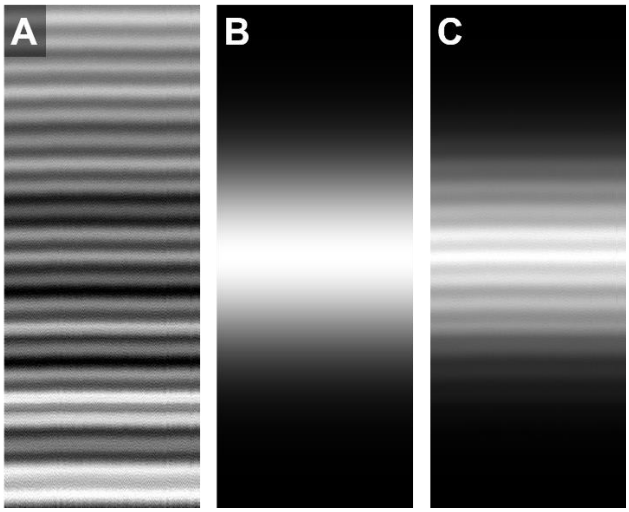


图2 我们在频域对OCT数据进行窗口化的过程（A）。使用高斯加窗掩模（B）并结合 α = 4 降低轴向分辨率，从而生成经过高斯加窗的频域数据（C）。

花卉数据集与准备

我们使用 TensorFlow 团队编制的开源花卉数据集[7]来初始化 OCT 超分辨率生成对抗网络的权重。该花卉数据集包含 3,670 张花卉图像。我们去除了花卉图像周围的黑色边框，将图像调整为 240x400，并在分配用于训练（3303 张）和测试（367 张）之前随机打乱图像顺序。

引入花卉数据集的伪影应模拟低轴向分辨率OCT B扫描图像的外观。因此，如图3所示，我们将原始高分辨率（HR）输入与 1×n 均值滤波器进行卷积，生成低分辨率图像，以便在垂直方向上对每个像素进行平滑处理；n 分别取 3、5、7、9 和 11 个像素。

[1] https://www.mathworks.com/help/signal/ref/gausswin.html

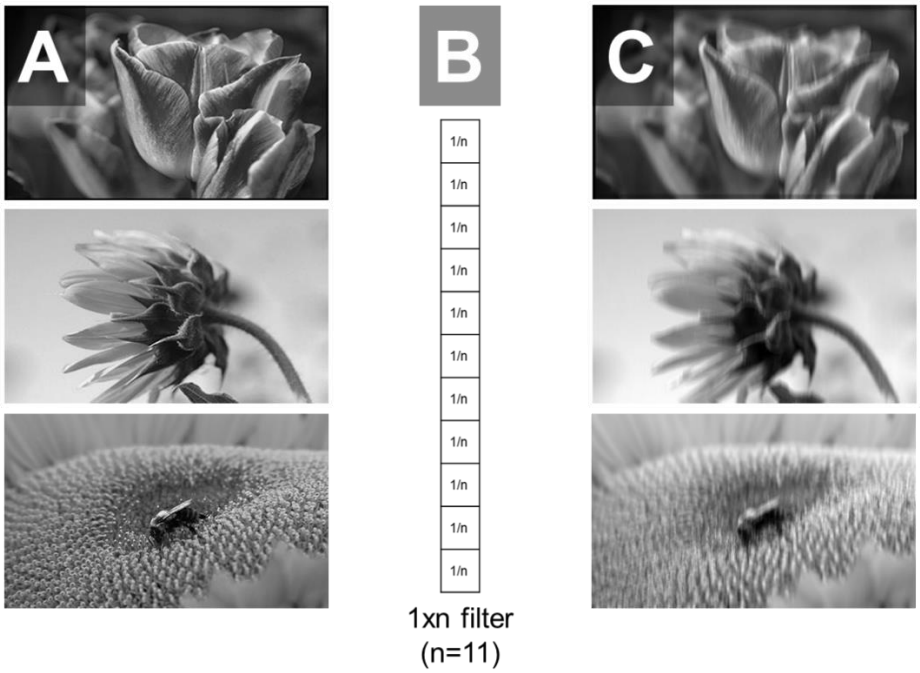


图3。示意　高分辨率花朵图像（A）的窗口化过程，使用垂直方向的 1xn，在此 ase
n=11，均值滤波器（B）生成单向（垂直）平滑图像（C）。

数据增强与GAN训练技术

在空间域重建中，我们使用 ImgAug 库进行水平翻转和垂直翻转以实现数据增强，从而扩大有效数据集规模并提高泛化能力。由于数据仅在 A扫描（垂直方向）上进行了平滑处理，因此未考虑旋转。此外，为避免干扰 OCT B扫描图像中散斑图案的重建，数据增强过程中没有引入随机噪声。在两个域中，数据均在预处理中进行了增强，训练期间未再进行进一步增强。对光谱域条纹数据进行的这些增强包括随机设置高斯窗口滤波器的中心和宽度，如图4所示。

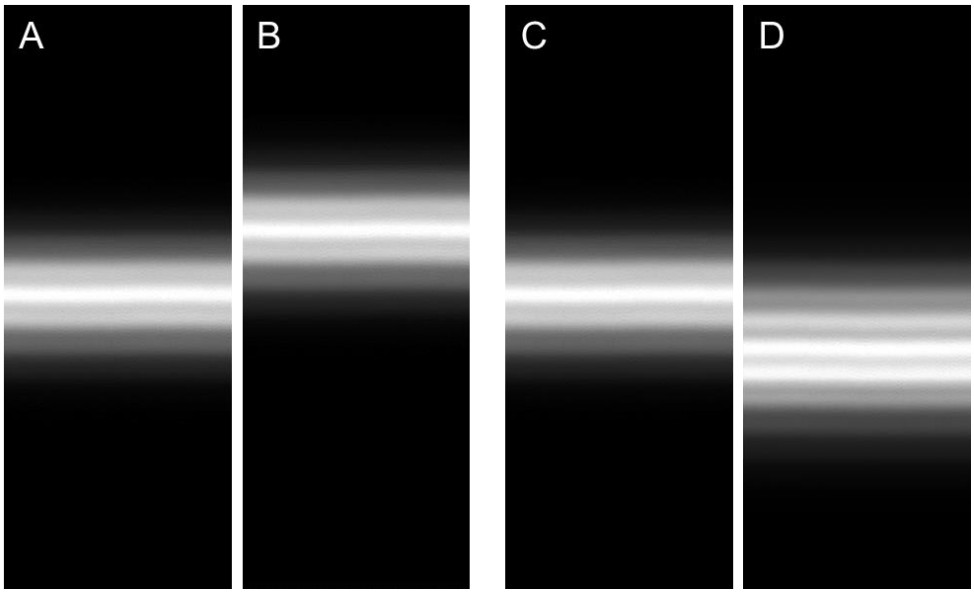


图4 光谱域条纹数据预处理过程中所进行随机增强的示意图：(A 和 C) 原始高斯窗加窗条纹数据；(B) 中心偏移；(D) 中心偏移并加宽。

我们参考了以往关于神经网络训练过程的文献 [9–13]，以改进 GAN 框架并促进收敛。分类神经网络使用软标签来降低错误率，这一方法已应用于 GAN 的对抗组件 [9–11]。实例噪声是一种随机翻转判别器训练标签的技术 [12, 13]。通过减少生成样本与真实样本之间的模糊性，这两种技术均用于提高 GAN 训练的稳定性，从而促进训练收敛。我们通过将真实标签随机分布在 (0-0.1) 范围内、将生成标签随机分布在 (0.9-1) 范围内，实现软标记。此外，我们以 5% 的概率随机向判别器提供错误标签，以引入实例噪声。判别器先使用一整批真实值数据进行训练，随后再使用一批生成数据进行训练。这种小批量特征方法使判别器能够将一批生成样本中的样本与真实样本进行比较，并检测不同小批量之间的相似性 [9, 14]。

神经网络设计

空间域特征恢复网络

首先，我们提出了文献 [6] 中所述超分辨率生成对抗网络的一种变体。我们实现的超分辨率生成对抗网络并未通过亚像素卷积层（PixelShuffler x2）将较小图像放大为较大图像，而是移除了亚像素分辨率层，并将该网络架构用于 pix2pix 应用，以保留 B 扫描分辨率，如图5所示。

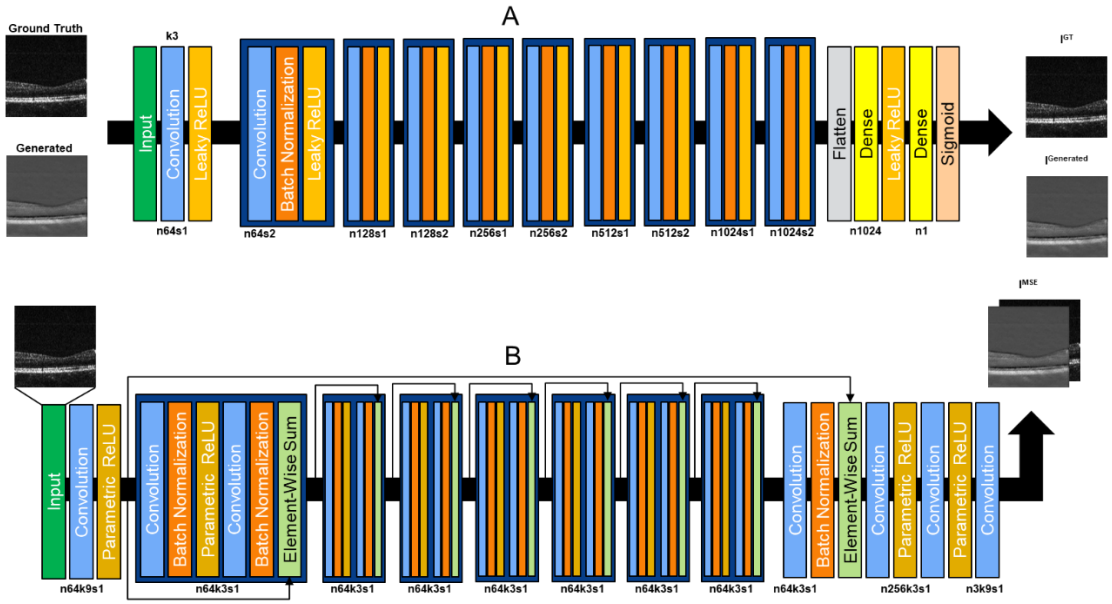


图5 超分辨率生成对抗网络（SRGAN）架构。架构（A）是基于 VGG网络的判别器，架构（B）是由残差块组成的生成器。损失函数包括判别器对真实值（lGT）和生成图像（lGenerated）的二元交叉熵损失，以及生成图像与真实值之间的均方误差（lMSE）。

与超分辨率生成对抗网络 [6]相比，我们采用了更深的判别器和生成器，因为研究表明，更深的网络能获得更好的结果，但代价是训练难度更大 [15]。判别器由多个卷积块组成，其中包含二维卷积层；这些卷积层在网络越深处使用的滤波器越多，后接批归一化和 Leaky Rectified Linear Unit（LeakyReLU）。研究发现，批归一化能够改善 GAN优化 [9、16]，而 LeakyReLU 有助于获得更好的结果，尤其是在高分辨率实现中 [16]。在生成器中，我们使用参数化ReLU；它是一种具有可学习负斜率的 LeakyReLU，并结合批归一化和通过逐元素加法实现的跳跃连接，构成残差块。跳跃连接使网络能够向前传递一些简单特征，而这些特征可能难以通过卷积滤波器学习 [6、17]。

频域特征恢复网络

在研究空间域与光谱域超分辨率的第二步中，神经网络内的所有组件，包括卷积滤波器、池化滤波器等，均使用垂直一维滤波器。这确保神经网络能够明确地独立处理各个 A扫描。高斯加窗仅应用于 A扫描，且每个 A扫描彼此独立。

频域重建处理的图像中，相关信息集中在 B 扫描中心附近，并向图像末端呈高斯分布的衰减强度。生成器经过更新，通过在卷积层中使用膨胀率来考虑像素间的距离，这会增大卷积滤波器之间的间隔。参考已发表的 ResUNet-a架构 [18]，采用了多种膨胀率并行处理：每个批归一化块和激活层之后都接有一个采用不同膨胀率的一维卷积层。采用了多达 8 个并行块，每个块使用不同的膨胀率，使神经网络能够探索距离较远的像素之间的关系。采用不同膨胀率的并行卷积块通过跳跃连接与恒等函数相加进行组合。图6以图示形式概述了所用的不同构建模块，包括并行应用膨胀率以构建 ResUNet-a 生成器，如图7所示。

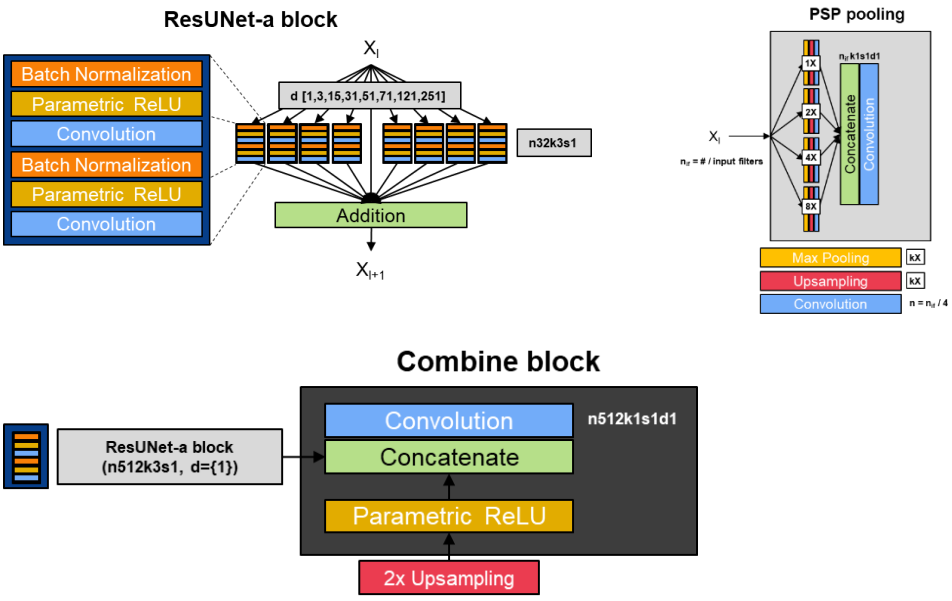


图 6 如 [18] 所述的 ResUNet-a 构建模块。

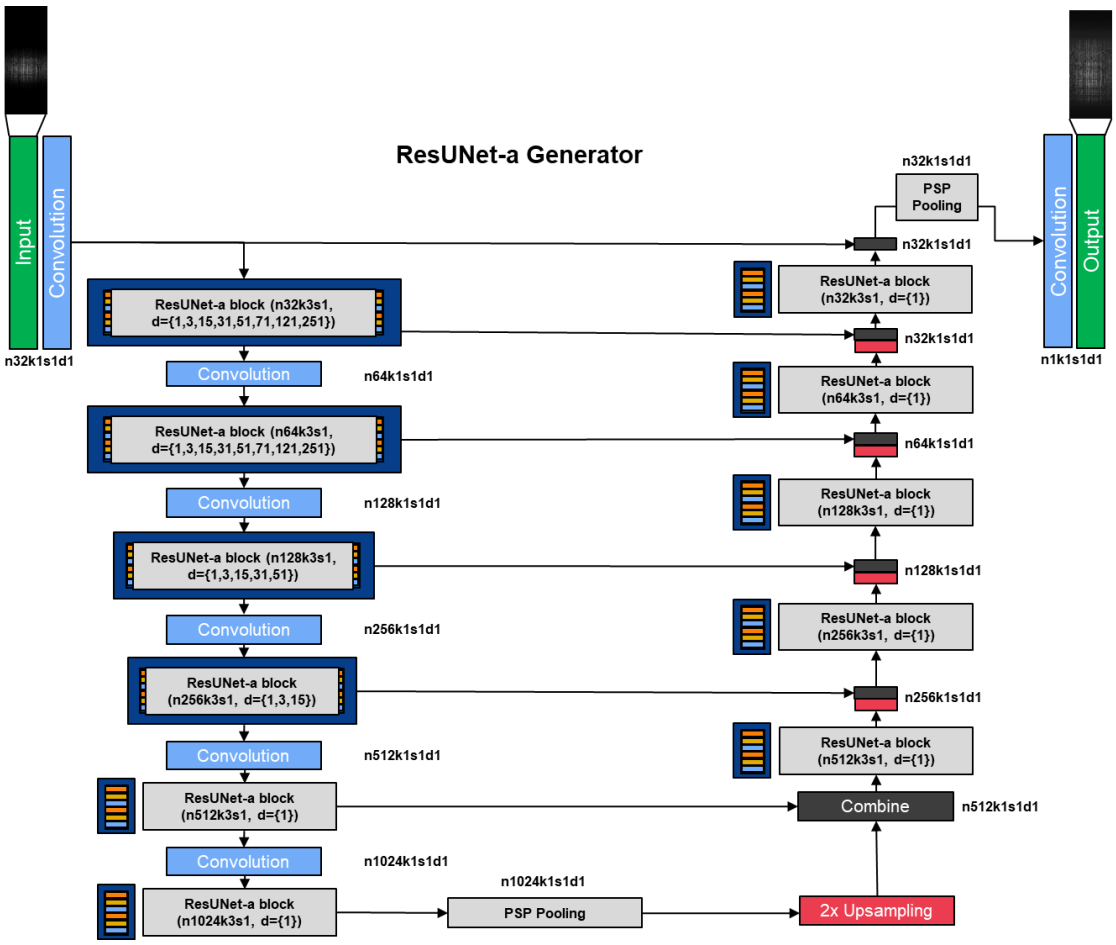


图7 重　　用于在光谱　　领域。

特征恢复网络训练的实验设置

两项实验的深度神经网络训练均以相似方式进行。所用优化器为 Adam，参数为 β1 = 0.5。通过采用不同学习率计划进行快速训练，确定了最佳学习率。在所有实验中，判别器和生成器均采用最佳初始学习率 1x10-4。初步实验中，超分辨率生成对抗网络训练了 200 个训练轮次，批次大小为 32。第二项实验针对尺寸为 1024x400 的图像进行，训练了 100 个训练轮次，批次大小为 10。初步实验和第二项实验中，超分辨率生成对抗网络的训练与评估分别耗时 24 小时和 52 小时。

内容损失（lMSE）通过逐像素均方误差（MSE）计算。判别器分别使用真实值和生成图像的小批次进行训练，得到两个二元交叉熵损失（lGT、lgenerated），这两个损失反映了生成器欺骗判别器的能力。对于生成器 lMSE 损失更低、判别器 lGT 更高或 lgenerated 损失更高的模型，均予以保存。初步实验使用在天然花卉数据集上训练的超分辨率生成对抗网络（SRGAN）进行权重初始化，随后用于 OCT B扫描训练；所有神经网络参数均可训练。所有深度神经网络均使用 Python 3.6.3，通过 TensorFlow 和 Keras API 开发并评估，运行于配备 NVIDIA Tesla V100-SXM2 GPU 和 32GB 随机存取存储器的加拿大超级计算机“Cedar”节点上。

评估

对生成对抗网络的评估通常是定性的，因为一些细微的伪影可能会显著影响均方误差、峰值信噪比（PSNR）和结构相似性（SSIM）等评估指标 19。例如

在我们的特征重建实现中，相较于图像强度的精确程度，我们可能更看重 OCT 层边界的清晰度；而有些评估指标可能会根据神经网络的功能进行加权。因此，一种方法是请人工标注员根据研究的功能和目标对生成对抗网络的性能进行评分，这也称为平均意见分（MOS）[8]、[9]。

为改进对生成结果的定性评估，我们裁剪了视网膜层附近的图像区域，并使用最近邻插值放大图像，以保留像素分辨率；随后将其与真实值及窗函数滤波/均值滤波图像进行定性比较，从而更清楚地观察和比较特征。对于初步实验，我们在整个测试集上使用均方误差、峰值信噪比和结构相似性，对模型的整幅图像进行了定量评估。对于完整数据集上的实验，则采用均方根误差和结构相似性进行评估。

4. 结果 – 初步迁移学习

我们采用多种滤波器尺寸（1x3、1x5、1x7、1x11）对花朵神经网络进行垂直模糊处理。使用经 1x11 滤波平滑处理的花卉图像训练的超分辨率生成对抗网络，在将其作为 OCT B 扫描的初始化权重时效果最佳。因此，在迁移学习实验中，神经网络以经 1x11 滤波平滑处理的花卉图像进行初始化。

定性评估

我们直接使用 OCT 超分辨率生成对抗网络，从低轴向分辨率 B 扫描重建高轴向分辨率图像，成功增强了光学相干断层扫描图像的特征。如图9（A–C）所示，为进行定性评估，我们使用最近邻插值裁剪并放大了相同区域。

如图8所示，我们的花朵超分辨率生成对抗网络的结果，以及使用 1x11 均值滤波器重建垂直平滑处理的效果，表明该方法有望恢复因平滑处理而丢失的特征。

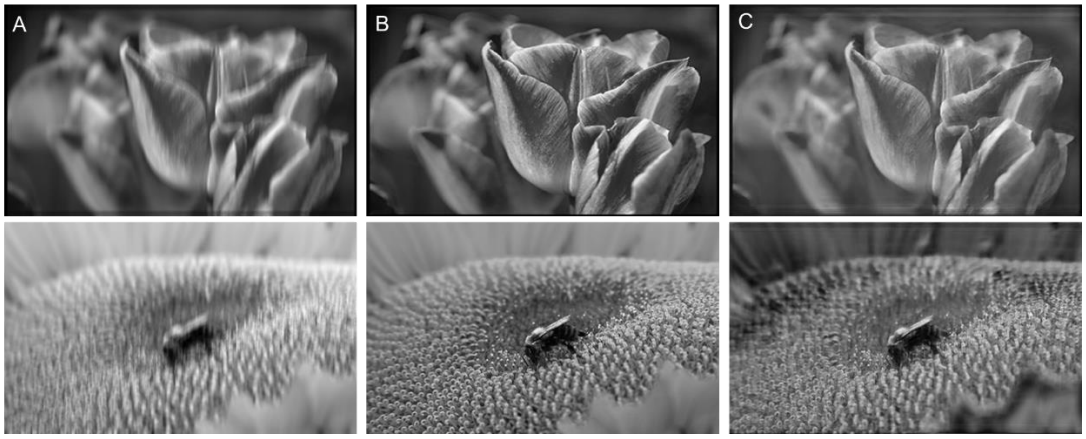


图8 花朵超分辨率生成对抗网络对比：（A）经过 1×11 均值滤波器处理的图像，（B）真实值，以及（C）测试集中的生成图像。

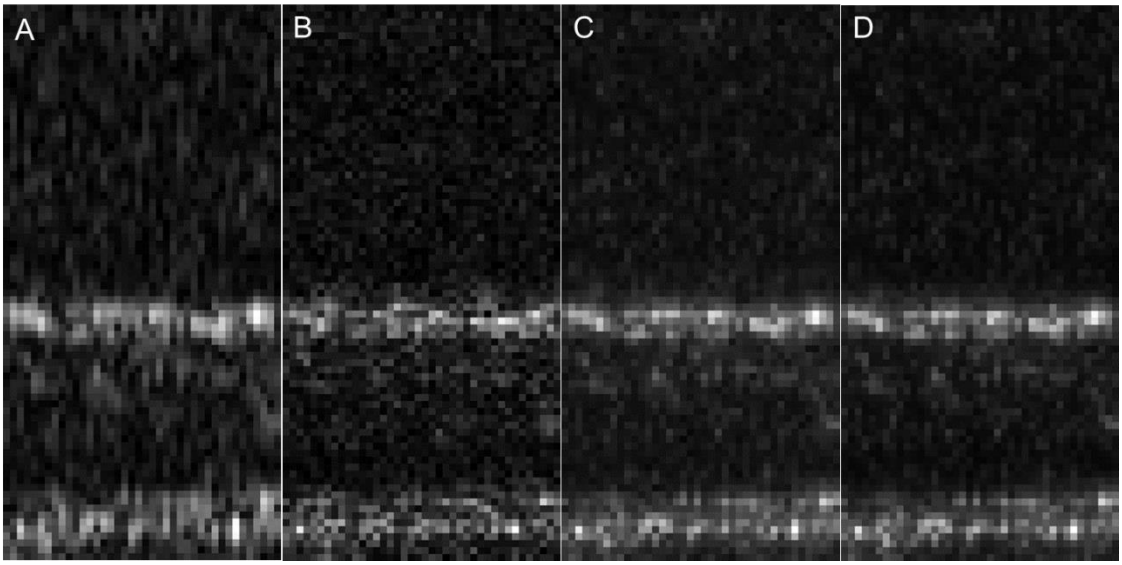


图9 结果　　超分辨率生成对抗网络对 OCT B扫描图像的结果。测试集中生成图像的样本。对比 (A) 加窗图像、(B) g round truth，以及 (C) 未使用迁移学习生成的 B 扫描和 (D) 使用迁移学习生成的 B 扫描。

定量评估

如表1所示，在对比度调整后，使用均方误差和结构相似性评估整个 OCT B扫描图像在测试集中生成图像与真实图像之间的相似度。并将结果与高斯窗处理／垂直平滑处理后的图像和真实图像之间的基线比较进行了对照。

由于生成输出的功能或目标往往具有主观性，因此很难对其性能进行定量评估；不过，通过对图像进行标准化，并使用相同的流程增强所有图像的对比度，强度差异带来的问题得以最小化。这样一来，我们的指标便能更侧重于特征，而非绝对强度。表1显示，在各项评估指标中，生成的 B 扫描与原始高分辨率B扫描图像更为相似。

表1。生成图像（GEN）的定量评估：比较仅使用OCT与采用自然图像迁移学习的方法。括号内为标准差，所示为均值。本部分实验在整个数据集（35只眼睛）的一个子集（16只眼睛）上进行。

Test	**GEN vs. GT**		**Windowed vs. GT**	
	MSE	***SSIM***	***MSE***	***SSIM***
No Transfer Learning (16 Volumes)	**71.04 (36.67)**	**0.753 (0.059)**	100.42 (38.66)	0.713 (0.051)
With Transfer Learning (16 Volumes)	**68.07 (40.38)**	**0.767 (0.067)**	100.42 (38.66)	0.713 (0.051)

针对特定测试，生成图像与加窗图像之间的最佳值以粗体显示。
均方误差（MSE）和结构相似性（SSIM）。真实值（GT）

5. 结果 – 空间域与光谱域中的重建

预处理方法显著影响了在初步数据集和完整数据集上进行训练的比较，因为所使用的裁剪算法不同。本节使用整个 1024x400 B 扫描；相比之下，初步实验将图像裁剪为 470x400 B 扫描图像。

然而，在本次实验中，空间域和光谱域采用的评估方法一致，仅在部分最终处理和评估步骤所使用的函数上略有不同。

定性评估

对于空间超分辨率生成对抗网络，在未使用迁移学习的情况下，使用了来自 27 位不同患者的全部 35 只眼睛；图10展示了测试集中两张扫描图像中捕获视网膜层的裁剪区域。

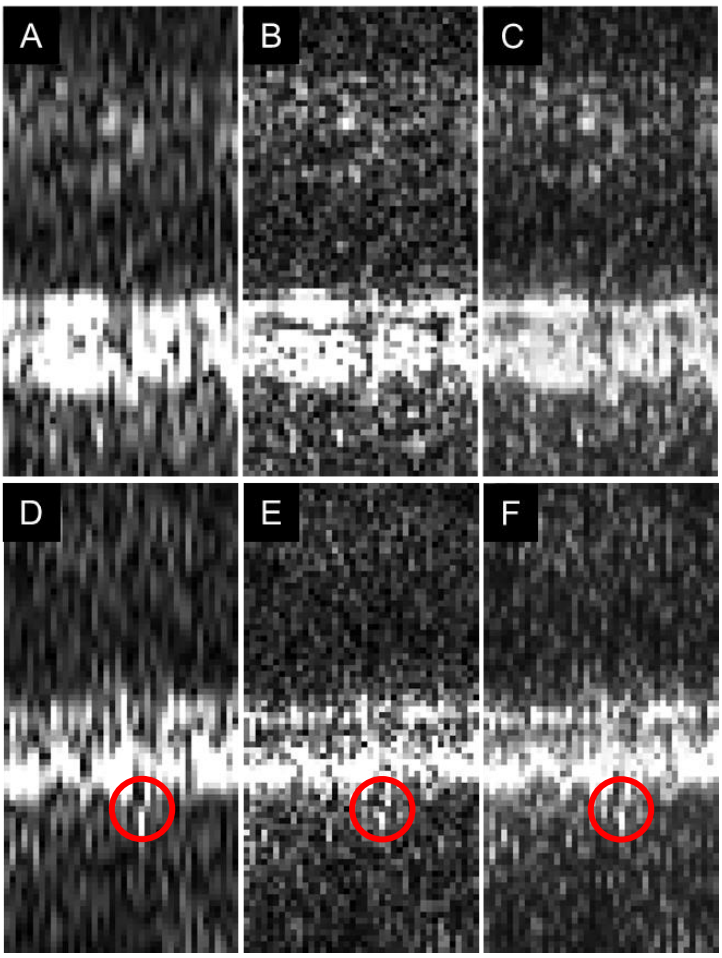


图10. 在完整 OCT B扫描数据集（35 只眼睛）上，不使用迁移学习的空间超分辨率生成对抗网络的结果。测试集生成图像中的样本。对比（A 和 D）窗口化图像、（B 和 E）真实值以及（C 和 F）生成的 B 扫描。红色圆圈标示感兴趣区域。

使用由光谱域重建的完整数据集训练模型，图11展示了测试集中一只眼睛的裁剪区域。图12还展示了测试集中的另一个示例。数据在各个 A扫描之间相互独立，应据此进一步探究。图13以图形方式比较了条纹数据的强度。

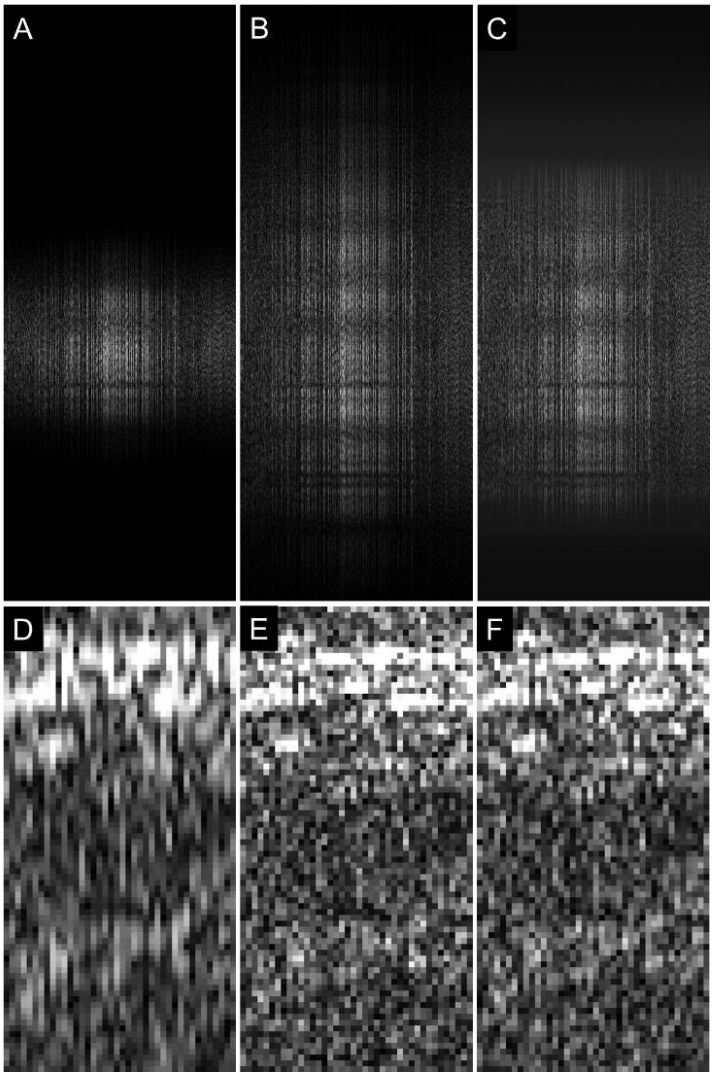


图11. 在完整数据集（35只眼睛）的 OCT B扫描图像光谱条纹上训练的光谱 SRGAN 的结果。测试集中生成图像的样本。比较：(A) 加窗条纹数据，(B) 真实条纹数据，(C) 生成条纹数据，(D) 加窗空间域数据，(E) 由真实光谱数据经傅里叶变换得到的空间域数据，以及 (F) 由生成光谱数据经傅里叶变换得到的空间域数据。

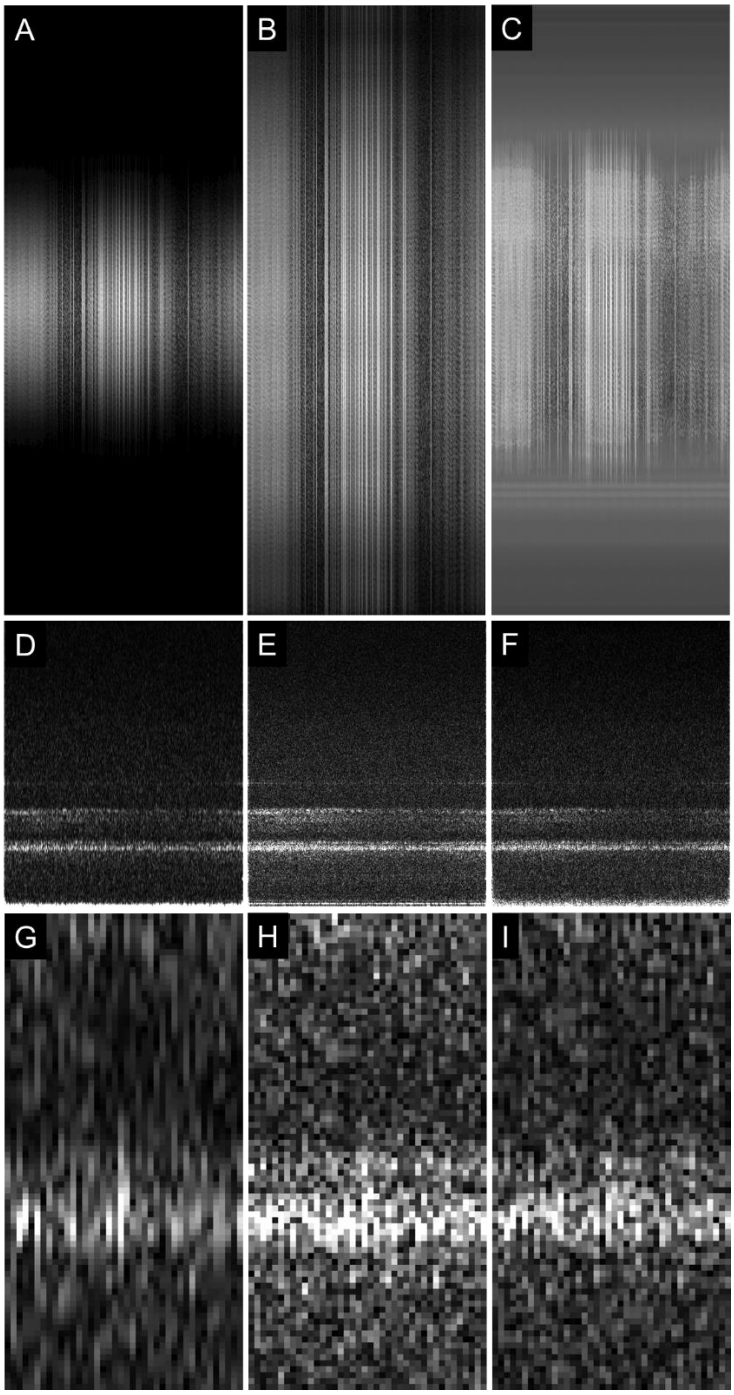


图12. 在完整数据集（35 只眼睛）的 OCT B扫描图像光谱条纹上训练的超分辨率生成对抗网络可能出现的失败案例。测试集生成图像中的样本。（A）加窗条纹数据、（B）真实条纹数据、（C）生成条纹数据、（D）加窗空间域数据、（E）真实空间域数据、（F）生成空间域数据、（G）裁剪后的加窗数据、（H）裁剪后的真实数据和（I）裁剪后的生成数据的比较。

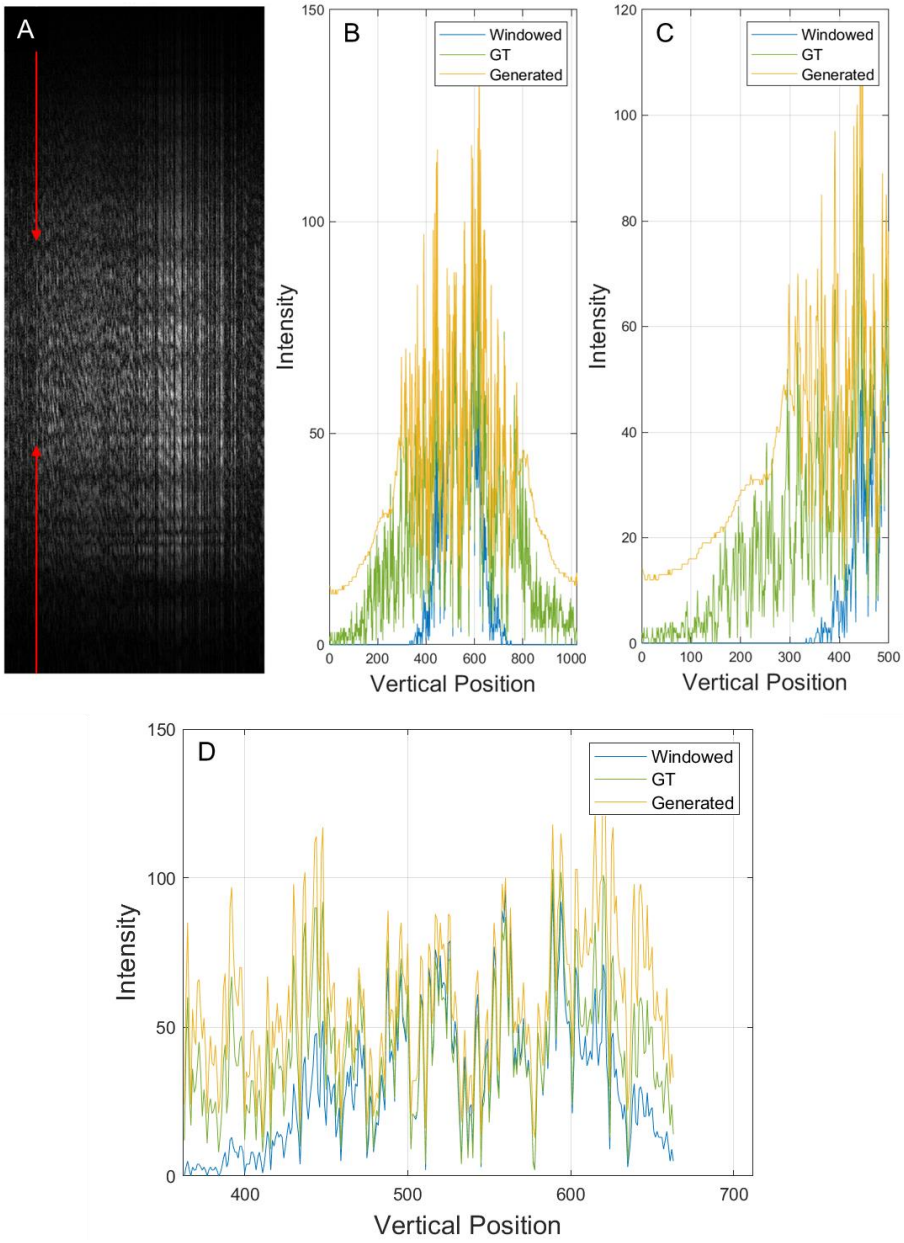


图13. 在完整数据集（35 只眼睛）的 OCT B扫描图像光谱条纹上训练的超分辨率生成对抗网络的结果。展示测试集生成图像中的样本。黄色为生成的 A扫描，与橙色的真实值（GT）和蓝色的加窗条纹进行比较。(A) 展示 B 扫描及红色箭头标出的感兴趣区域的 A 扫描。(B) 展示光谱域中的完整 A 扫描。(C) 检视图像上半部分，以便了解生成器在条纹边缘附近的表现（边缘通常代表高频信号和光谱噪声）。(D) 检视中央 300 个像素。

定量评估

本实验在整个数据集上进行，其评估比初步研究更为全面。对空间域与光谱域重建进行了峰值信噪比评估，并对均方误差进行归一化后开平方，以提供更标准化的范围，便于比较不同尺度的模型。表2对光谱域和空间域重建的性能进行了定量比较。

表2. 对比在光谱域与空间域中进行重建的生成对抗网络（GAN）图像的定量评估。评估前，光谱域图像已转换至空间域。数值以均值表示，括号内为标准差。

Test	GAN vs. GT			Windowed vs. GT		
	NRMSE	***PSNR***	***SSIM***	***NRMSE***	***PSNR***	***SSIM***
Spatial Domain Reconstruction	**0.3390 (0.021)**	**22.31 (1.02)**	**0.6867 (0.041)**	0.4239 (0.016)	20.36 (0.886)	0.579 (0.069)
Spectral Domain Reconstruction	**0.3403 (0.044)**	**21.25 (1.03)**	**0.7874 (0.048)**	0.4394 (0.026)	18.98 (0.773)	0.652 (0.029)

针对特定测试，生成图像与加窗图像中的最佳值以粗体标出。缩写：归一化均方根误差（NRMSE）、峰值信噪比（PSNR）和结构相似性（SSIM）。真实值（GT）

6. 讨论

随着光学相干断层扫描硬件逐渐转向采集更大视野、涵盖视网膜更多周边区域的图像，为了让患者更舒适并减少运动伪影，可能会牺牲轴向分辨率，以尽量缩短采集时间。由此导致的光谱域带宽降低，会妨碍微米级分辨率的实现，而这正是采用该成像方式的优势之一。本研究模拟轴向分辨率降低的情况，并旨在重建丢失的特征。本研究的贡献如下：（1）探讨利用自然图像数据集进行迁移学习，以初始化 OCT 超分辨率生成对抗网络的效果；（2）比较在光谱域与空间域中进行重建的效果。

已有研究探讨了在光学相干断层扫描（OCT）数据中使用超分辨率生成对抗网络（SRGAN）。研究人员利用生成对抗网络（GAN）进行超分辨率处理，通过重建空间域下采样造成的特征丢失[20]、散斑去除[21–23]、域适应[24]、合成视网膜疾病[26]或其他成像模态[27]等。近期，一些研究团队开始利用生成对抗网络（GAN）进行超分辨率处理。他们通过对光谱域数据加窗，模拟低轴向分辨率的光学相干断层扫描（OCT）数据，并在空间域中进行重建[28–31]。据我们所知，本研究首次利用生成对抗网络（GAN）在光谱域中重建模拟的光谱带宽缩减数据，应用于眼科光学相干断层扫描（OCT）数据。

本实验的初步步骤旨在了解迁移学习对基于生成对抗网络的光学相干断层扫描数据重建的影响。如图9所示，利用在花卉数据集上预训练权重的超分辨率生成对抗网络成功重建了光学相干断层扫描数据。视网膜层的散斑纹理等特征尤其变得更加清晰。然而，与生成对抗网络对花卉数据集中平滑特征重建所产生的显著效果相比，这种影响较小（比较图9 C和D）。定量评估也反映了这一点。通过迁移学习，使用自然花卉图像初始化超分辨率生成对抗网络后，生成图像的均方误差略有改善，但结构相似性略低于仅使用光学相干断层扫描数据的方法。不过，两种方法的所有指标差异均在一个标准差范围内。这些结果令人鼓舞，也让我们有信心继续使用完整数据集开展研究。

随着初步试验的推进，我们在降低光谱带宽时采用了不同的窗口化 alpha 值。alpha 值为 8 时，足以观察轴向分辨率降低所产生的影响。从花卉数据集进行迁移学习取得了相对不错的效果，以花卉数据集初始化的神经网络能够略微缩短训练时间。然而，为了模拟空间域 OCT 图像中轴向分辨率降低的效果，我们对花卉数据集应用了均值滤波器。为了进行公平比较，光谱域神经网络也必须从相似域迁移知识。两种方法之间的差异支持采用不进行迁移学习的方法。采用迁移学习的试验，其评估指标的平均值更优；但同时，均方误差和结构相似性的标准差也更高。鉴于这种方法的性能方差较低，且具有更大的灵活性，我们决定在第二个实验中不采用迁移学习。如果采用迁移学习，则每次对神经网络进行修改，都需要对花卉数据集进行相应修改并重新训练。

按照文献[8]中的建议，我们选择花卉数据集，用于重建射线图像中的低分辨率图像。花瓣复杂的纹理和图案提供了高对比度边缘。对图像应用垂直滤波器时，与对更均匀的图像进行处理相比，模糊效果会更加明显。我们还应进一步探索从更相似的领域（例如超声）进行迁移学习。这样，我们就能了解从相似领域进行迁移学习所产生的影响，并将其与选择一个旨在夸大预期效果的数据集进行比较。

第二项实验比较了空间域和光谱域中的重建效果。两项实验为训练、验证和测试分配了相同的眼睛。预处理和评估使用了相同的函数。然而，舍入方式、保存格式和处理流程顺序的差异导致图像出现了细微变化，如表2所示。用于设定评估指标基线的列——该指标用于比较加窗图像与真实图像——理想情况下应完全相同，因为生成对抗网络不会影响这两组图像。然而，数据在光谱域和空间域的不同阶段被保存为图像。训练还要求在训练前将数据标准化至 [-1, 1] ，并在评估时标准化至 [0, 1] 。比较这两个域时，必须考虑标准化、舍入和处理顺序方面的所有差异。为复现生成图像所发生的变化，真实值和加窗条纹也经过了相同的处理流程。

在对重建效果进行定性评估时，两种方法都成功重建了丢失的特征。在空间域中，如图10所示，背景中的散斑图案和视网膜层看起来都更加清晰。不过，即使经过强度归一化，仍能观察到轻微的强度变化。参见图10（D-F），真实图像中脉络膜区域的一条垂直线（红圈标出）约有3像素长。在对应的加窗图像和生成图像中，该特征分别约有4-5像素和3-4像素长。在光谱域中，如图11所示，生成条纹数据（C）能够重建高斯窗尾部附近的特征。图13以图形形式展示了随机选取的一个A扫描，其位置由（A）中的箭头标出。对A扫描边缘中心（C）和A扫描中心（D）的放大视图证实，生成器能够重建因高斯加窗而丢失的特征。（D）所示的中心附近，生成信号能够重建真实值中的图案。观察作为信号上半部分的（C）可见，在距中心200像素以内，信号看起来相似；而加窗信号的强度几乎已降至零。因此，我们得出结论：加窗图像中残留的微弱信号，加上图像中心附近的图案，足以使生成对抗网络重建被高斯加窗抑制的特征。

评估表2所示各项指标的均值时，空间域生成对抗网络在归一化均方根误差和峰值信噪比方面优于光谱域生成对抗网络，而光谱域生成对抗网络在结构相似性方面表现更优。不过，比较右栏中的加窗图像与真实图像时，可以明显看出这些趋势。评估生成图像时，两种方法之间的差异也都在一个标准差以内。因此，我们得出结论：两种方法效果相当，均能有效重建因光谱带宽缩减而丢失的特征。

光谱域模型在15个训练轮次内（约10万次训练迭代）完成优化。图14展示了一个失败案例，说明在训练19个轮次时发生了过拟合。检查发现，条纹数据中包含周期性垂直条纹图案；将其转换到空间域后，视网膜上方的区域被移除。相比之下，空间域生成对抗网络可以训练约80个轮次而不过拟合。应进一步探究这一问题，因为它可能是由条纹数据之间的相似性导致的，也可能是需要调整学习率调度器。

7. 局限性与未来工作

SRGAN 研究受限于缺乏与传统“反卷积”方法的比较。我们比较了一个利用从自然花卉数据集迁移学习的模型的性能，但缺乏与其他传统编程重建技术进行公平比较。该研究还可以通过探索光谱域中的重建，以及研究其他定性评估方法而获益。一些研究团队通过平均意见分，将定性评估转化为定量评估：随机征询一组专家，请其在生成方法、加窗方法及其他替代方法中选出最佳方法。这是评估生成方法优势的一个潜在途径，及

其生成的超分辨率图像的性能。然而，这需要专家的意见，整个过程可能耗时较长。受我先前工作[24]的启发，另一种评估方法是使用其他处理工具：使层分割工具偏向高分辨率域，然后根据分割性能评估生成的超分辨率图像。

图12考察了一种潜在的失败案例，其中条纹数据包含垂直线伪影。尽管这些线条在视觉上不太美观，超分辨率生成对抗网络仍能够重建特征。经目视检查，带宽似乎没有像其他示例那样大幅增加。然而，将图像转换到空间域后，可以明显看出生成对抗网络仍成功重建了丢失的特征。

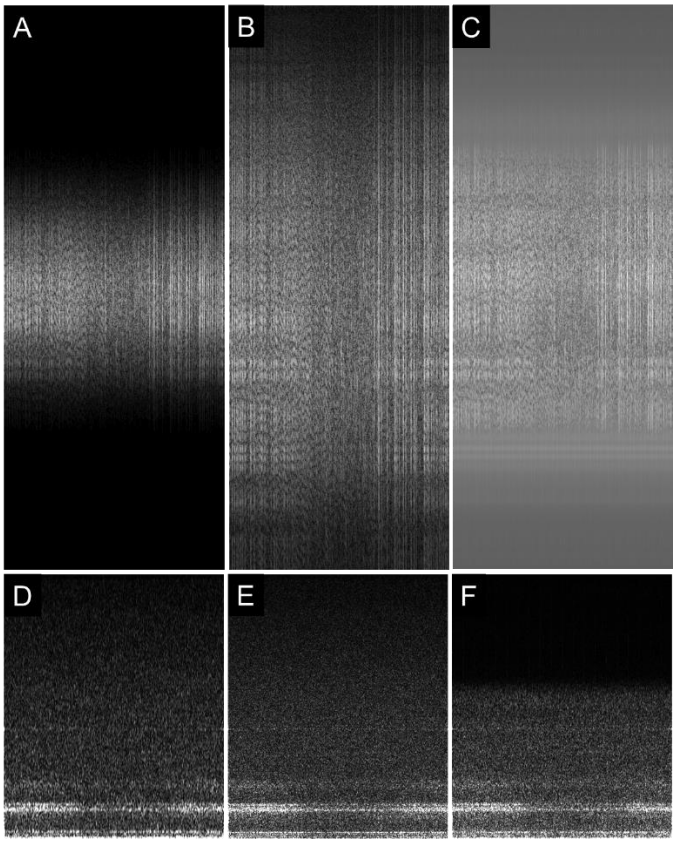


图14. 在完整数据集（35只眼睛）上，使用光学相干断层扫描 B 扫描图像的光谱条纹训练的过拟合超分辨率生成对抗网络（19个训练轮次）的结果。测试集生成图像中的样本。对比（A）加窗条纹数据、（B）真实条纹数据、（C）生成条纹数据、（D）加窗空间域数据、（E）真实空间域数据和（F）生成空间域数据。

未来工作包括将空间域 A扫描纳入光谱域生成对抗网络的损失函数，反之亦然。其他未来工作还包括将来自两个域的生成对抗网络整合到一个处理流程中，探索从超声或音乐频率信号等相似数据域进行迁移学习，并研究在空间域中使用 ResUNet-a架构。

8. 利益冲突

MVS：Seymour Vision, Inc. (I).

9. 参考文献

1. Kwan CC, Fawzi AA. 糖尿病性黄斑水肿和糖尿病视网膜病变的成像与生物标志物。Curr Diab Rep. 2019;19(10). doi:10.1007/s11892-019-1226-2 2. Karst SG, Heisler M, Lo J, et al. 利用扫频源 OCTA 评估视网膜不同区域中糖尿病继发的微血管病变迹象。Investig Ophthalmol Vis Sci. 2020;61(5). doi:10.1167/IOVS.61.5.8

3. Wang J, Camino A, Hua X, et al. 基于不变特征的广域 OCT 血管造影自动配准与拼接。Biomedical Optics Express. 2019;10(1). doi:10.1364/boe.10.000120 4. Zhang Q, Huang Y, Zhang T, et al. 利用运动跟踪提供的基于光学相干断层扫描的微血管造影，对视网膜血管系统进行广域成像。Journal of Biomedical Optics. 2015;20(6). doi:10.1117/1.jbo.20.6.066008 5. Gao M, Guo Y, Hormel TT, Sun J, Hwang TS, Jia Y. 使用深度学习重建高分辨率 6×6-mm OCT 血管造影图。Biomedical Optics Express. 2020;11(7):3585. doi:10.1364/boe.394301 6. Ledig C, Theis L, Huszár F, et al. 使用生成对抗网络实现照片级单图像超分辨率。载于：第30届 IEEE 计算机视觉与模式识别会议论文集，CVPR 2017。第 2017-January 卷。；2017。doi:10.1109/CVPR.2017.19 7. TensorFlow. Flowers. 在线发表于 2019 年。8. Moran MBH, Faria MDB, Giraldi GA, Bastos LF, Conci A. 利用超分辨率生成对抗网络模型和迁移学习获得高分辨率数字根尖周X线片。Comput Biol Med. 2021;129. doi:10.1016/j.compbiomed.2020.104139 9. Salimans T, Goodfellow I, Zaremba W, Cheung V, Radford A, Chen X. 改进 GAN 训练技术。载于：神经信息处理系统进展。；2016。10. Goodfellow IJ, Bulatov Y, Ibarz J, Arnoud S, Shet V. 使用深度卷积神经网络从街景图像中识别多位数字。载于：第2届国际学习表征会议，ICLR 2014——会议论文集。；2014。11. 扰动、优化与统计学。；2018。doi:10.7551/mitpress/10761.001.0001 12. Sønderby CK, Caballero J, Theis L, Shi W, Huszár F. 图像超分辨率的摊销映射推断。载于：第5届国际学习表征会议，ICLR 2017——会议论文集。；2017。13. Jenni S, Favaro P. 关于通过噪声稳定生成对抗训练。载于：IEEE计算机视觉与模式识别学会会议论文集。第 2019-June 卷。；2019。doi:10.1109/CVPR.2019.01242 14. Goodfellow IJ, Pouget-abadie J, Mirza M, Xu B, Warde-farley D. 生成建模 生成建模。Annual Plant Reviews. 在线发表于 2016 年。15. Simonyan K, Zisserman A. 用于大规模图像识别的超深卷积网络。载于：第3届国际学习表征会议，ICLR 2015——会议论文集。；2015。16. Radford A, Metz L, Chintala S. 利用深度卷积生成对抗网络进行无监督表征学习。第4届国际学习表征会议 ICLR 2016——会议论文集。在线发表于 2016 年：1-16。17. He K, Zhang X, Ren S, Sun J. 深度残差网络中的恒等映射。载于：欧洲计算机视觉会议。；2016：630-645。18. Diakogiannis FI, Waldner F, Caccetta P, Wu C. ResUNet-a：用于遥感数据语义分割的深度学习框架。ISPRS J Photogramm Remote Sens. 2020;162:94-114. doi:10.1016/j.isprsjprs.2020.01.013 19. Wang Z, Bovik AC, Sheikh HR, Simoncelli EP. 图像质量评价：从误差可见性到结构相似性。IEEE Trans Image Process. 2004;13(4). doi:10.1109/TIP.2003.819861 20. Huang Y, Lu Z, Shao Z, et al. 基于生成对抗网络的光学相干断层扫描图像同步去噪与超分辨率。Opt Express. 2019;27(9). doi:10.1364/oe.27.012289 21. Dong Z, Liu G, Ni G, Jerwick J, Duan L, Zhou C. 使用散斑调制生成对抗网络对光学相干断层扫描图像进行去噪。J Biophotonics. 2020;13(4). doi:10.1002/jbio.201960135 22. Chen Z, Zeng Z, Shen H, Zheng X, Dai P, Ouyang P. DN-GAN：用于光学相干断层扫描图像散斑噪声抑制的去噪生成对抗网络。Biomedical Signal Processing and Control. 2020;55. doi:10.1016/j.bspc.2019.101632 23. Cheong H, Krishna Devalla S, Chuangsuwanich T, et al. OCT-GAN：一步去除人类视神经乳头光学相干断层扫描图像中的阴影与噪声。Biomedical Optics Express. 2021;12(3). doi:10.1364/boe.412156 24. Ricky Chen, TIMOTHY T. YU, Gavin Xu, DA MA, MARINKO V. SARUNIC MFB. 通过 CycleGAN 进行域适应，实现光学相干断层扫描中的视网膜分割。arXiv: 210702345 [eessIV]。在线发表于 2021 年。25. Zhang T, Cheng J, Fu H, et al. 用于医学图像分析的噪声自适应生成对抗网络。IEEE Trans Med Imaging. 2020;39(4). doi:10.1109/TMI.2019.2944488 26. Zheng C, Xie X, Zhou K, et al. 生成对抗网络模型用于视网膜疾病合成光学相干断层扫描图像的评估。Transl Vis Sci Technol. 2020;9(2). doi:10.1167/tvst.9.2.29 27. Lee CS, Tyring AJ, Wu Y, et al. 利用人工智能从结构光学相干断层扫描生成视网膜血流图。Sci Rep. 2019;9(1):5694. doi:10.1038/s41598-019-42042-y 28. Zhang Y, Liu T, Singh M, et al. 利用欠采样光谱数据，通过神经网络重建扫频源光学相干断层扫描图像。Light Sci Appl. 2021;10(1). doi:10.1038/s41377-021-00594-7 29. Lichtenegger A, Salas M, Sing A, et al. 使用条件生成对抗网络，从不连续光谱数据重建可见光光学相干断层扫描图像。Biomedical Optics Express. 2021;12(11). doi:10.1364/boe.435124 30. Cao S, Yao X, Koirala N, et al. 利用深度学习超分辨率技术，同时提升光学相干断层扫描的光学分辨率和数字分辨率。载于：IEEE医学与生物学工程学会年度国际会议论文集（EMBS）。第 2020-July 卷。；2020。doi:10.1109/EMBC44109.2020.9175777 31. Yu TT, Ma D, Cole J, Jin Ju M, Faisal Beg M, Sarunic M V. 使用深度学习进行光学相干断层扫描图像的光谱带宽恢复。载于：国际图像与信号处理及分析研讨会（ISPA）。第 2021-September 卷。；2021。doi:10.1109/ISPA52656.2021.9552122