



基于生成式对抗网络预测痤疮物理治疗效果的研究

段炼^{1,2†}, 董子瑜^{3†}, 杨琳^{1,2}, 张景伟³, 李博尉^{1,2}, 付大富², 苏夏雨^{1,2}, 杨晓东³, 蔡宏^{1,2*}

1. 中国人民解放军医学院, 中国人民解放军总医院, 北京 100853

2. 中国人民解放军空军军医大学, 空军特色医学中心皮肤科, 北京 100142

3. 中国科学院计算技术研究所, 北京 100190

† 同等贡献

* 联系人, E-mail: ch1031@163.com

2025-06-09 收稿, 2025-07-31 修回, 2025-09-10 接受, 2025-09-17 网络版发表

空军后勤部项目(BKJW221J009)资助

摘要 痤疮是一种常见的毛囊皮脂腺慢性炎症性疾病, 严重时可引起红斑、色素沉着以及永久性的瘢痕, 不仅会降低患者的生活质量, 同时也会引起焦虑、抑郁甚至自杀等心理问题。目前的治疗主要包括口服、外用药物以及物理治疗, 但使用传统的药物治疗有一定的副作用, 而且存在治疗时间长、依从性差等问题。相比之下, 物理治疗因安全性高, 疗效显著, 是药物干预不耐受或拒绝接受药物干预患者的首选方法。然而, 物理治疗包括强脉冲光治疗、化学换肤等多种方法, 患者在接受物理治疗后, 常表现出明显的个体化差异。皮肤科医生选择治疗方式依赖于临床经验, 低年资的医生缺乏相关的能力与知识, 无法作出更有利于患者的治疗选择。人工智能图像分析领域的发展为此提供了解决方案。生成对抗网络(generative adversarial network, GAN)是深度学习代表性模型之一。已成功应用于医学影像的增强和模拟疾病治疗效果等方向。因此, 本研究构建了基于循环一致性生成对抗网络(cycle-consistent generative adversarial network, CycleGAN)的痤疮物理治疗预后生成模型。共纳入756例痤疮患者, 通过裁剪, 共得到1709对痤疮治疗前后图像用于模型构建与性能验证。该模型能够生成与真实预后图像高度相似的模拟预测图像。本研究旨在构建一个能够准确生成痤疮物理治疗预后图像的预后模型, 帮助皮肤科医生选择最佳治疗方式, 为患者制定个体化治疗方案, 同时能够降低患者的试错成本, 避免无效或过度治疗。

关键词 痤疮, 生成对抗网络, 皮肤病, 深度学习, AI辅助医疗决策

痤疮是一种常见的毛囊皮脂腺慢性炎症性疾病, 多发于青少年^[1], 全球疾病负担研究显示, 痤疮的患病率为9.4%^[2]。其发病机制主要与雄激素水平异常、皮脂分泌过多等因素相关^[3]。临床表现为粉刺、丘疹、脓疱、结节甚至囊肿。严重的炎症可引起红斑、色素沉着以及永久性的瘢痕^[4], 进而大大降低患者的生活质量, 导致焦虑、抑郁等心理问题, 甚至出现自杀行为^[5,6]。

目前痤疮的治疗方法包括外用或口服维甲酸类药物、抗生素、物理治疗等, 治疗方法的选择主要取决

于痤疮的病变类型和严重程度。尽管传统的药物治疗应用广泛, 但仍存在许多不良反应^[7]。另外, 有研究表明, 口服维甲酸可能与抑郁症和自杀之间存在联系^[8], 而长期使用抗生素会增加细菌耐药性, 导致疗效下降, 同时还会改变肠道菌群和皮肤微生物群的组成^[9,10]。根据肠-脑-皮肤轴理论, 这两者的改变会进一步加重负面情绪以及痤疮的严重程度^[11,12]。相比之下, 物理治疗因安全性高、疗效显著, 正在成为对药物治疗不耐受或不愿意接受药物治疗的患者的首选方法。痤疮的物理治疗是指通过光、电、热、机械等非药物手段改善痤疮

引用格式: 段炼, 董子瑜, 杨琳, 等. 基于生成式对抗网络预测痤疮物理治疗效果的研究. 科学通报

Duan L, Dong Z, Yang L, et al. The use of generative adversarial networks to predict the physical outcomes of acne treatment (in Chinese). Chin Sci Bull, doi: 10.1360/CSB-2025-5076

疮症状的治疗方式,包括强脉冲光、红蓝光、化学换肤、激光治疗等.其中强脉冲光(intense pulsed light, IPL)可以同时解决痤疮、色素性疾病、血管性疾病、光老化等多种皮肤问题,并兼具无创、恢复周期短、安全性高、复发率低等优点^[13].化学剥脱,也称为化学换肤术,通过作用于皮肤表面的试剂,对皮肤造成不同程度的受控损伤,从而诱导皮肤表面和真皮结构的重建并抑制皮肤的炎症反应^[14].还可以有效地调节皮脂产生,溶解粉刺,并表现出抗炎和抗菌特性,而且在改善痤疮后色素沉着与浅表瘢痕上具有明确的疗效^[15].不同患者面对同一种治疗方式的反应表现出明显的异质性,并且同一患者在接受不同的物理治疗方式后也表现出显著的差异.然而,临床上对于痤疮物理治疗的选择主要依赖皮肤科医生的临床经验,低年资的医生往往不具备相应地能力与知识.因此,临床上需要一种能够准确预测痤疮物理治疗后的工具,辅助皮肤科医生作出治疗决策,为患者制定个体化治疗方案.

人工智能(artificial intelligence, AI)技术,尤其是图像分析领域的发展为上述问题提供了解决方案.近年来,深度学习(deep learning, DL)与医学的交叉研究,已成为热门领域.皮肤科疾病的诊断、治疗方法的选择和预后判断高度依赖视觉模式^[16],DL能够通过多层神经网络,自动提取临床照片、病理图像等数据的特征,完成多种临床任务,如疾病分类、病灶分割、解剖定位、疾病诊断以及病灶检测等^[17~22].生成对抗网络(generative adversarial network, GAN)作为DL的代表性模型之一,是一种生成式模型,由生成器(generator)和判别器(discriminator)组成,能够通过对抗训练生成高度逼真的数据^[23].GAN已成功应用于医学影像的增强与重建、病变区域生成和模拟疾病治疗效果等方向^[24~26].Rengot等人^[27]利用GAN来生成皱纹图片,构建了基于AI的标准化皱纹评估量表.Scott等人^[26]以StyleGAN2-ADA为框架,利用375张银屑病患者临床照片,通过数据增强生成了25000张图片进行训练,生成了与真实图片高度相似的银屑病虚拟图片.以上研究表明,GAN在医学图像生成领域具有重要的应用价值与潜力.GAN已经用于痤疮的临床诊疗流程中,Mascarenhas等人^[28]使用包含GAN等3个组件的模型,对模糊的痤疮患者图像进行处理,准确勾勒出面部特征,并去除模糊模块,增加图像清晰度,帮助医生作出更准确的诊断.Zein等人^[29]基于痤疮图像的公共数据集生成合成的痤疮患者图像,在确保痤疮图像可用性和真实

性的同时,保证了数据的匿名性和安全性.该研究所生成的图像使用InceptionResNetv2进行训练,实现了97.6%的准确率.以上研究表明,GAN用于皮肤科临床诊疗流程是一个很值得期待的研究方向,但是目前该方向的研究仍处于初步发展阶段.

循环一致性生成对抗网络(cycle-consistent generative adversarial network, CycleGAN)是GAN模型的一种变体主要用于无监督图像转换任务,能够在保留解剖结构的基础上调整图像的对比度或纹理特征^[30].已经有研究将CycleGAN在视网膜成像等方面的研究^[31,32].这一GAN变体的出现为我们解决皮肤科临床难题,提供了新的答案和方向.

因此,本研究通过将计算机视觉的技术应用于痤疮诊疗流程,可视化展现痤疮物理治疗的预测效果.针对3种常用的物理治理方法(IPL、化学换肤以及两者联合治疗),构建了基于CycleGAN的痤疮物理治疗预后生成模型.旨在通过该模型生成预测图像,辅助皮肤科医生作出最佳医疗决策,制定个体化治疗方案.使患者更好地临床获益,减少医疗成本.

1 材料和方法

1.1 数据收集

本研究回顾性地收集2022年5月~2024年5月空军特色医学中心皮肤科激光中心门诊诊断包含“痤疮”的病历数据.本研究依据《赫尔辛基宣言》进行,并经过空军特色医学中心内部审查委员会(空特科研第2022-227-YJ01)批准.

所有图像数据是由固定的3名工作人员,使用尼康Z711相机拍摄.要求纳入的受试者同时满足以下全部条件:(1) 年龄12~60周岁;(2) 明确诊断为痤疮;(3) 仅接受强脉冲光、化学换肤或二者联合治疗,治疗前未使用任何口服或外用抗痤疮药物;(4) 具备完整治疗记录及清晰、可评估的前后照片.凡出现以下任一情况即予排除:(1) 诊断存疑或错误;(2) 妊娠或哺乳期;(3) 需系统治疗的聚合性或暴发性痤疮;(4) 合并活动性皮肤感染或皮损区域存在干扰性皮肤病;(5) 照片被记号笔、配饰污染或遮挡;(6) 图像文件损坏;(7) 治疗记录不完整;(8) 前后照片在光照、拍摄距离或角度上存在显著差异.最后共得到756例患者.按治疗方式分为三组:IPL治疗组($n=392$),化学换肤组($n=168$),IPL+化学换肤组($n=196$).

1.2 图像采集与预处理

所有图像均在标准化条件下由3名工作人员进行拍摄。拍摄参数包括：固定拍摄距离50 cm、交叉偏振光模式，以确保图像一致性。原始图像保存为无损压缩的PNG格式。将患者治疗前和不同治疗方式单次治疗后的患者照片通过专业图像处理软件(ImageJ v1.53)进行预处理：首先，手动框选目标痤疮病灶区域，统一裁剪方形区域，至少保留中心病变及周围5 mm正常皮肤作为背景；随后，根据治疗前痤疮病灶位置，对该患者单次治疗后同一病灶图像进行裁剪。并将同一病灶经过1次治疗前后的图像通过统一命名方式进行配对，以便后续分析。最终纳入分析的1709对图像。裁剪后的图像均通过双人核对确保裁剪位置一致。

1709对图像包括IPL组798对，化学换肤组391对，联合治疗组520对。每个治疗组内的数据按照8:2的比例随机划分为训练集和验证集。训练集用于模型训练，验证集用于超参数调优和测试真实图像与生成图像的相似性。

为了提高模型对不同图像采集条件和实际干扰因素的鲁棒性，我们在数据预处理阶段设计了一系列数据增强策略。首先，通过将图像放大至原目标尺寸的1.12倍后随机裁剪，以模拟不同的拍摄距离和位置偏差；其次，随机水平翻转操作增加了图像的左右对称性，从而丰富了训练样本；同时，我们采用了ColorJitter进行颜色扰动，随机调整亮度、对比度、饱和度及色调，模拟了不同光照条件下皮肤表现的变化；此外，随机旋转一定角度的操作进一步提升了模型对图像旋转和倾斜变换的适应性；最后，加入自定义的高斯噪声，使得模型在面对噪声干扰时也能提取到稳定的特征。通过多重数据增强，我们有效扩充了数据多样性，为生成对抗网络提供了丰富的图像样本。

1.3 模型构建

本研究采用CycleGAN模型对痤疮物理治疗前后皮肤状态进行建模。模型构建过程见图1。CycleGAN由两个生成器和两个判别器构成，分别用于实现正向与反向的图像转换。在CycleGAN的训练过程中，生成器和判别器交替更新，通过对抗损失驱动生成器生成模拟图像，同时利用循环一致性损失(cycle consistency)确保图像转换过程中的结构信息得以保留。生成器不仅通过正向转换模拟治疗后的皮肤状态，还通过反向

转换重构原始图像，强化了模型对图像细节的捕捉和保留。此外，身份映射损失(identity mapping loss)在一定程度上约束了生成器在转换过程中不引入过多不必要的变化。通过这种多重损失函数的联合优化，模型能够逐步提升图像转换质量，实现不同领域间的有效映射，为进一步的应用提供坚实基础。在模型训练过程中，设定总训练周期为600，采用Adam优化器对模型参数进行更新，初始学习率为0.0001，batch size设置为8。为增强训练过程的稳定性与模型的泛化能力，引入LambdaLR学习率调度策略，并将学习率衰减周期设置为100。该策略结合总训练周期数与预设的衰减周期，对学习率进行动态调整，实施线性衰减机制，从而缓解模型在训练后期陷入局部最优的风险。模型的训练以及后续的实验均在两块NVIDIA RTX 4090 GPU中实现。

2 结果和讨论

2.1 模型训练过程

为了评估模型在不同治疗条件下的训练稳定性与收敛特性，图2展示了三种不同治疗方式下生成器损失的变化趋势。可以观察到，所有曲线在训练初期损失值较高，随着训练的进行，损失值逐渐下降，表明模型在不断学习并优化其生成能力。随着训练的深入，损失曲线的下降速度逐渐放缓，最终趋于平稳。这种现象表明模型已经达到了一个相对稳定的状态。

2.2 生成图像的客观指标分析

为了评估GAN生成图像的质量，以及是否具有与真实治疗后图像相似的真实度，使用验证集中350张真实治疗后的图片和350张生成的图片进行对比评估。图3(a)分别对两组图像的红、绿、蓝通道的原始像素强度进行检测，并将结果绘制成直方图。图中显示，真实图像组与GAN生成图像组三种颜色通道的像素强度分布趋势大致相似，表明CycleGAN正确地学习到了颜色相关的规律，并且对治疗后的图像能够准确地再现出来。图3(b)中纵坐标为图像平均饱和度，横坐标为平均亮度，每一个点代表一张图片。两组的散点分布区域相似，证明生成图像具有与真实图像相似的照明条件和颜色饱和度。

结构相似性指数(structural similarity index measure, SSIM)是一种基于人类视觉系统特性的图像质量




图1 模型构建流程。首先将确诊痤疮患者按治疗方法分为强脉冲光、化学换肤和联合治疗三组,在标准化照明条件下采集面部照片,并对治疗前后的痤疮皮损图像进行配对、裁剪和配准对齐;随后将配对图像按8:2比例划分为训练集和验证集。在CycleGAN模型构建中,生成器G_AB负责将治疗前图像转换为模拟治疗后状态,G_BA则执行逆向转换,同时由判别器D_A和D_B评估生成图像的真实性

Figure 1 Model construction workflow. Patients diagnosed with acne were first stratified into three treatment groups: intense pulsed light, chemical peeling, and combination therapy. Facial photographs were acquired under standardized lighting conditions. Paired pre- and posttreatment acne lesion images were then cropped and coregistered. The paired images were subsequently split into training and validation sets at an 8:2 ratio. Within the CycleGAN framework, generator G_AB translates pretreatment images into simulated posttreatment states, whereas G_BA performs the reverse transformation; discriminators D_A and D_B concurrently assess the authenticity of the generated images

评价指标,通过比较生成图像与真实图像在亮度(luminance)、对比度(contrast)和结构(structure)三个维度的相似性进行综合评分^[33]。本研究分别对3个治疗组治疗后真实图像与生成图像计算了SSIM。如图3(b)所示,SSIM值范围为[-1,1],值越接近1表示两幅图像结构相

似性越高。结果显示,所有治疗组的SSIM值均接近完美匹配。其中化学换肤组的SSIM值最高(99.87%),IPL治疗组次之(99.85%),而IPL+化学换肤联合治疗组的SSIM值略低(99.84%),但三组间的差异无统计学意义。这一结果表明,GAN模型能够高度精确地模拟不同治疗方式对痤疮皮损的影响,生成图像在亮度、对比度和结构特征上与真实治疗后图像几乎无法区分。联合治疗组的SSIM值稍低可能与其更复杂的治疗反应有关,但整体仍维持在极高水平,说明模型对不同治疗策略的适应性良好。此外,SSIM值接近100%也提示生成图像在像素级结构上具有极高的保真度。

2.3 皮肤科医生对生成图像的主观评估

本研究从验证集随机抽取50对图像分为A、B两组,其中A组25对均为生成图像(真实治疗前图像+GAN生成治疗后图像),B组25对包含12对生成图像(真实治疗前图像+GAN生成治疗后图像)和13对真实图像(真




图2 三种治疗方法在600个训练周期内的损失曲线

Figure 2 Loss curves of the three treatment methods over 600 epochs




图3 痤疮治疗GAN生成图像的定量分析结果。(a) 真实图像与生成图像的RGB通道像素强度分布对比；(b) 色彩指标分析：平均饱和度与亮度的相关性；(c) 3种治疗方式(强脉冲光、化学换肤、联合疗法)的生成图像与真实图像的结构相似指数

Figure 3 Quantitative analysis of GAN-generated acne treatment images. (a) Pixel intensity distributions in RGB channels are observed by comparing real and generated images; (b) a color metric analysis was performed by plotting mean saturation versus luminance; (c) the structural similarity index between generated images and real images for three therapeutic modalities (IPL, chemical peeling, and combination therapy) is shown

实治疗前图像+真实治疗后图像)，所有图像经过匿名编号和随机排序后，由3名资深皮肤科医师独立判断每对图像中的“治疗后”图像是真实图像还是生成图像。评估前未告知医师各组图像中真实图像与生成图像的比例构成。图4(a)和(c)中分别展示了I组和II组图像的医生判断结果，对勾和叉号分别表示该医生作出了正确或错误的判断。图4(b)表示的是皮肤科医生对I组(全部为生成图像)的判断结果统计，结果显示，绿色条带表示该名医生正确判断为生成图像，红色条带表示错误地将生成图像判断为真实图像。结果显示，3名医生对I组图像的平均识别准确率为46%，表明生成图像在视觉上与真实图像相似性较高，容易导致判断混淆。图4(d)表示的是对II组(12对生成图像和13对真实图像)判断的结果统计，蓝色、橘色、绿色和红色条带分别代表将真实图片识别为真实图片，将真实图片识别

为生成图片，将生成图片识别为真实图片，将生成图片识别为生成图片。仅有一名医生正确区分真实图像和生成图像的概率高于50%，达到了60%。综合3名医生的判断结果，正确识别出真实图像的准确率为64%，正确识别出生成图像的准确率为32%，总体正确区分图像的准确率为52%。综上所述，CycleGAN生成的图像能够以较高的保真度模拟真实治疗后的图像，使得临床经验丰富的皮肤科医生难以准确区分。

2.4 基于CycleGAN的痤疮物理治疗预后生成模型的辅助决策

如图5所示，该模型应用于临床的工作流程包括：首先对就诊的痤疮患者进行标准化皮损图像采集，随后将获取的临床图像输入经过优化的CycleGAN模型，并分别生成3种治疗方式(强脉冲光、化学换肤以及联




图4 皮肤科医生评估生成图像。(a, c) 3名皮肤科医生(A、B、C)对50张痤疮临床图像进行评估,区分真实治疗后图像与生成图像。每张图像右上角的3个字母代表医生对每张图的判断结果,例如:RGR代表3名医生分别认为这张图是“real (真实图像)”“generated (生成图像)”“real (真实图像)”。(b) 皮肤科医生对生成图像的识别结果。(d) 皮肤科医生从CycleGAN生成的图像中区分真实痤疮治疗后临床图像的表现

Figure 4 Dermatologists' evaluation of generated images. (a, c) Three dermatologists (A, B, and C) evaluated 50 clinical acne images to distinguish between real posttreatment images and generated images. The three letters in the upper right corner of each image represent the determinations of the three doctors with regard to that image. For example, "RGR" indicates that the three doctors classified the image as "real", "generated", and "real". (b) The dermatologists' identification results for the generated images are shown. (d) The dermatologists' performances with regard to distinguishing real posttreatment clinical acne images from those generated by CycleGAN




图 5 基于CycleGAN的痤疮物理治疗预后生成模型的辅助决策。本图展示了以下工作流程：(1) 对痤疮患者皮损区域进行标准化图像采集；(2) 将临床图像输入优化后的CycleGAN模型，生成三种治疗方式(强脉冲光、化学换肤及联合治疗)的疗效模拟预测图像；(3) 皮肤科医师基于这些治疗模拟结果制定个性化最优治疗方案

Figure 5 Flowchart of the CycleGAN-based visual decision support system for acne treatment planning. The workflow: (1) standardized acquisition of lesional images from acne patients; (2) processing of clinical images through an optimized CycleGAN model to generate simulated posttreatment predictions for three therapeutic modalities (IPL, chemical peeling, and combination therapy); and (3) dermatologists' formulation of personalized optimal treatment strategies based on these therapeutic simulations

合治疗)治疗后的模拟预测图像。皮肤科医师根据所生成的模拟图像，为患者制定个性化的治疗策略。该系统的临床应用价值主要体现在：(1) 通过可视化预测实现精准医疗，显著提高治疗方案选择的科学性；(2) 有效规避传统治疗中的试错过程，为患者节省治疗成本；(3) 缩短治疗决策周期，减少复诊需求。

为了验证临床医师能否通过三种治疗方案的模拟预测图像达成一致的决策判断，将验证集的50张治疗前图像输入CycleGAN模型，成功生成了IPL治疗、化学换肤治疗及联合治疗后的预测图像(部分图像如图6)。随后由5名资深皮肤科医生根据生成图像进行治疗方案选择，并对三名医生所作出的决策进行一致性分析，计算Cohen's Kappa系数，并根据Landis & Koch标准对结果进行判读(0.00~0.20轻微一致、0.21~0.40一般一致、0.41~0.60中等一致、0.61~0.80高度一致、0.81~1.00几乎完全一致)。结果显示(表1)，除医生A和B，医生A和E外，5名医生的Cohen's Kappa系数均在0.6以上，达到了高度一致。医生A和B一致性最低($\kappa=0.554$)，为中等一致，医生C和E一致性最高($\kappa=0.879$)，达到了机会完全一致。医生A与其他医生一致性均较低，通过与医生A沟通发现，作出不同医疗决策的原因大部分是由于当联合治疗组治疗效果略强于单一治疗方案组时，

该医生考虑到治疗费用问题选择了单一治疗方案。该结果证实，CycleGAN生成的预后图像能够帮助医生作出具有临床一致性的决策。

3 结论

痤疮是全球高发的慢性炎症性皮肤病，其治疗应基于循证医学制定个体化方案。在采用传统药物的同时，应警惕其潜在副作用。而化学换肤、激光等新兴技术为痤疮治疗提供了更安全、有效的选择。但是在临床上，如何选择最佳的物理治疗方案是临床医生，尤其是低年资医生困扰的问题。AI技术，特别是图像分析领域的快速发展，为我们提供了解决此问题的方案。本研究使用计算机视觉技术生成痤疮物理治疗后图像，并证明所生成的图像在客观指标与临床医生主观判断两个维度上均与真实图像高度相似。表明本模型能够通过CycleGAN准确预测痤疮物理治疗的效果，并将其以图像的形式展现出来。可以帮助低年资的皮肤科医生作出更合理的临床决策，达到为病人制定个体化治疗方案的目标。但是本研究仍有其局限性：(1) 用于训练模型的数据在光照条件和拍摄角度方面存在偏差，导致数据质量不足，模型训练效率尚待提高；(2) 拍摄时的体位、光照以及手动裁剪等难以避免存在差异，获




图 6 50张治疗前图像输入CycleGAN模型, 成功生成了强脉冲光治疗、化学换肤治疗及联合治疗后的预测图像, 5名资深皮肤科医生根据生成图像进行治疗方案选择. I、II、III 分别代表强脉冲光、化学换肤和联合治疗

Figure 6 Fifty pretreatment images were processed using the CycleGAN model, successfully generating predicted posttreatment outcomes for IPL therapy, chemical peeling, and combination therapy. Five board-certified dermatologists evaluated the generated images to determine the optimal treatment selection. I, II, and III represent intense pulsed light, chemical peeling, and combination therapy, respectively

表 1 5位医生基于GAN生成痤疮预后图像的诊疗决策两两一致性检验^{a)}

Table 1 Pairwise Cohen's Kappa coefficients among five physicians evaluating acne treatment decisions based on GAN-generated prognostic images

医生	一致(n, %)	不一致(n, %)	Cohen's Kappa
A和B	35, 70	15, 30	0.554
A和C	37, 74	13, 26	0.613
A和D	38, 76	12, 24	0.645
A和E	36, 72	14, 28	0.586
B和C	41, 82	9, 18	0.729
B和D	44, 88	6, 12	0.819
B和E	41, 82	9, 18	0.729
C和D	43, 86	7, 14	0.785
C和E	46, 92	4, 8	0.879
D和E	42, 84	8, 16	0.757

a) 每2名医生之间的Cohen's Kappa值, $P<0.05$

取的图像无法做到像素级对齐, 对结果的精度产生一定影响, 导致无法使用需要对数据配对要求更高的模型; (3) 测试样本数量有限, 无法全面验证本模型辅助决策的可靠性; (4) 由于数据的可获取性, 未加入多模态数据(例如患者年龄、性别、皮损严重程度、激素

水平等), 模型的性能仍有较大的进步空间.

此外, 还可以进一步将口服药物治疗以及外用药物治疗的预后模型作为未来的研究方向, 系统性地对痤疮进行疾病管理. 同时, 还可以考虑将大语言模型与GAN模型适当整合, 使其执行更加复杂、精确的任务.

参考文献

- 1 Heng A H S, Chew F T. Systematic review of the epidemiology of acne vulgaris. *Sci Rep*, 2020, 10: 5754
- 2 Tan J K L, Bhate K. A global perspective on the epidemiology of acne. *Br J Dermatol*, 2015, 172: 3–12
- 3 Thiboutot D, Gollnick H, Bettoli V, et al. New insights into the management of acne: an update from the Global Alliance to Improve Outcomes in Acne Group. *J Am Acad Dermatol*, 2009, 60: S1–S50
- 4 Min S, Park S, Yoon J, et al. Fractional microneedling radiofrequency treatment for acne-related post-inflammatory erythema. *Acta Derm Venerol*, 2016, 96: 87–91
- 5 Gieler U, Gieler T, Kupfer J. Acne and quality of life – impact and management. *Acad Dermatol Venereol*, 2015, 29: 12–14
- 6 Bertha E A, Balázs J. Subthreshold depression in adolescence: a systematic review. *Eur Child Adolesc Psychiatry*, 2013, 22: 589–603
- 7 Shalita A R. Mucocutaneous and systemic toxicity of retinoids: monitoring and management. *Dermatology*, 1987, 175: 151–157
- 8 Hu P, van Dam A M, Wang Y, et al. Retinoic acid and depressive disorders: evidence and possible neurobiological mechanisms. *Neurosci BioBehav Rev*, 2020, 112: 376–391
- 9 Thompson K G, Rainer B M, Antonescu C, et al. Minocycline and its impact on microbial dysbiosis in the skin and gastrointestinal tract of acne patients. *Ann Dermatol*, 2020, 32: 21
- 10 Moura I B, Grada A, Spittal W, et al. Profiling the effects of systemic antibiotics for acne, including the narrow-spectrum antibiotic sarecycline, on the human gut microbiota. *Front Microbiol*, 2022, 13: 901911
- 11 Chen Y, Peng L, Li Y, et al. Amplicon-based analysis reveals link between adolescent acne and altered facial skin microbiome induced by negative emotional states. *Front Cell Infect Microbiol*, 2025, 15: 1543616
- 12 Bowe W P, Logan A C. Acne vulgaris, probiotics and the gut-brain-skin axis—back to the future? *Gut Pathog*, 2011, 3: 1
- 13 Yu S L, Gui Y, Chen J J, et al. Clinical application of intense pulsed light in the treatment of acne (in Chinese). *Dermatol Bull*, 2023, 40: 669–675 [余恕玲, 桂禹, 陈家杰, 等. 强脉冲光在痤疮治疗中的临床应用. *皮肤科学通报*, 2023, 40: 669–675]
- 14 Chen X, Wang S, Yang M, et al. Chemical peels for acne vulgaris: a systematic review of randomised controlled trials. *BMJ Open*, 2018, 8: e019607
- 15 Kontochristopoulos G, Platsidaki E. Chemical peels in active acne and acne scars. *Clin Dermatol*, 2017, 35: 179–182
- 16 Cannarozzo G, Nisticò S P, Nouri K, et al. Clinical photography and noninvasive optics. In: Cannarozzo G, Nisticò S P, Nouri K, et al., eds. *Atlas of Lasers and Lights in Dermatology*. Cham: Springer International Publishing, 2020. 63–66
- 17 Tschandl P, Rosendahl C, Akay B N, et al. Expert-level diagnosis of nonpigmented skin cancer by combined convolutional neural networks. *JAMA Dermatol*, 2019, 155: 58
- 18 Esteva A, Kuprel B, Novoa R A, et al. Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, 2017, 542: 115–118
- 19 Wahba M A, Ashour A S, Guo Y, et al. A novel cumulative level difference mean based GLDM and modified ABCD features ranked using eigenvector centrality approach for four skin lesion types classification. *Comput Methods Programs Biomed*, 2018, 165: 163–174
- 20 Chatterjee S, Dey D, Munshi S. Integration of morphological preprocessing and fractal based feature extraction with recursive feature elimination for skin lesion types classification. *Comput Methods Programs Biomed*, 2019, 178: 201–218
- 21 She Q, Sun S, Ma Y, et al. LUCF-net: lightweight U-shaped cascade fusion network for medical image segmentation. *IEEE J Biomed Health Inform*, 2025, 29: 2088–2099
- 22 R.p. A, Zacharias J. Semantic segmentation in skin surface microscopic images with artifacts removal. *Comput Biol Med*, 2024, 180: 108975
- 23 Hussain J, Báth M, Ivarsson J. Generative adversarial networks in medical image reconstruction: a systematic literature review. *Comput Biol Med*, 2025, 191: 110094
- 24 Zhao H, Zhu W, Jin L, et al. Calcium deblooming in coronary computed tomography angiography via semantic-oriented generative adversarial network. *Computized Med Imag Graphics*, 2025, 122: 102515
- 25 Zhang H, Xu T, Li H, et al. StackGAN++: realistic image synthesis with stacked generative adversarial networks. *IEEE Trans Pattern Anal Mach Intell*, 2019, 41: 1947–1962
- 26 Scott J, Grant-Jacob J A, Praeger M, et al. Modifying the severity and appearance of psoriasis using deep learning to simulate anticipated improvements during treatment. *Sci Rep*, 2025, 15: 7412
- 27 Rengot J, Prestat-Marquis E, Aime I, et al. SCAWA scales: a new digital tool for wrinkles clinical grading based on AI. *Intern J Cosmetic Sci*, 2025, 47: 240–259
- 28 Mascarenhas P P, Sannidhan M S, Pinto A J, et al. Improving acne severity detection: a GAN framework with contour accentuation for image deblurring. *Front Bioinform*, 2025, 5: 1485797
- 29 Zein H, Chantaf S, Fournier R, et al. Generative adversarial networks for anonymous acneic face dataset generation. *PLoS One*, 2024, 19: e0297958

- 30 Zhang M, Sun Q, Han Y, et al. Cycle generative adversarial Transformer network for MRI brain tumor segmentation. [Neural Comput Applic](#), 2025, 37: 11379–11398
- 31 Harini P, Madhavi N B, Latha S B, et al. Optimized self-attention based cycle-consistent generative adversarial network adopted melanoma classification from dermoscopic images. [Microsc Res Technique](#), 2024, 87: 1271–1285
- 32 Alimanov A, Islam M B. Retinal Image Restoration using Transformer and Cycle-Consistent Generative Adversarial Network. In: 2022 Int Symp Intell Signal Process Commun Syst ISPACS, 2022
- 33 Adeshina A M, Razak S F A, Yegarayan S, et al. Measuring fidelity of steganography approach in securing clinical data sharing platform using peak signal to noise ratio (PSNR) and structural similarity index measure (SSIM). [Informatica](#), 2025, 49: 45–56

Summary for “基于生成式对抗网络预测痤疮物理治疗效果的研究”

The use of generative adversarial networks to predict the physical outcomes of acne treatment

Lian Duan^{1,2†}, Ziyu Dong^{3†}, Lin Yang^{1,2}, Jingwei Zhang³, Bowei Li^{1,2}, Dafu Fu², Xiayu Su^{1,2}, Xiaodong Yang³ & Hong Cai^{1,2*}

¹ Chinese PLA Medical School, Chinese PLA General Hospital, Beijing 100853, China

² Department of Dermatology, Air Force Medical Center, Air Force Medical University, Beijing 100142, China

³ Institute of Computing Technology, Chinese Academy of Sciences, Beijing 100190, China

† Equally contributed to this work

* Corresponding author, E-mail: ch1031@163.com

Acne vulgaris is a prevalent chronic inflammatory disorder of the pilosebaceous unit that is clinically characterized by comedones, papules, pustules, nodules, and cysts. Severe inflammation may induce erythema, hyperpigmentation, and permanent scarring, significantly compromising patients' quality of life and potentially leading to psychological sequelae such as anxiety, depression, and suicidal ideation. Current therapeutic approaches primarily include systemic/topical medications and physical therapies. However, conventional pharmacotherapy is often limited by adverse effects, protracted treatment duration, and suboptimal adherence. In contrast, physical therapies, noted for their superior safety profile and clinical efficacy, have emerged as the preferred treatment for patients who are intolerant or averse to pharmacological interventions. Physical therapies for acne use nonpharmacological modalities (such as optical, electrical, thermal, or mechanical techniques) to ameliorate symptoms and include intense pulsed light (IPL), red/blue light therapy, chemical peels, laser treatments, and microneedling. Current clinical practice relies heavily on dermatologists' subjective judgment for selecting physical therapies, with significant variability attributed to differences in clinical experience among practitioners. Moreover, marked interindividual heterogeneity in treatment response and the absence of standardized objective evaluation metrics underscore the need for tools capable of personalized prediction of therapeutic outcomes, particularly through accurate simulation of posttreatment lesion appearances.

Recent advancements in artificial intelligence (AI), particularly deep learning (DL), have revolutionized clinical applications including disease classification, lesion segmentation, anatomical localization, diagnostic support, and pathological detection. Notably, generative adversarial networks (GANs) have demonstrated exceptional proficiency in synthesizing highly realistic data via adversarial training, with successful implementations in medical image enhancement/reconstruction, pathological region generation, and therapeutic outcome simulation. These capabilities position GANs as an ideal framework for generating predictive post-treatment acne images to guide clinical decision-making.

This study retrospectively analyzed medical records flagged for “acne” from the Laser Center of Dermatology at the Air Force Medical Center. In accordance with stringent inclusion/exclusion criteria, 756 acne patients were enrolled and stratified into three cohorts: IPL monotherapy, chemical peel monotherapy, and combination therapy. The target acne lesions were manually annotated, with square regions cropped to uniformly encompass the central pathology and >5 mm of surrounding normal skin. Posttreatment images of the same lesions were aligned and cropped analogously, yielding 1709 images. All of the cropped images underwent dual review to ensure positional consistency. A total of 1709 images were partitioned into training and validation sets (8:2 ratio) without overlap. To bolster robustness against imaging variability and real-world artifacts, data augmentation strategies were implemented during preprocessing. The synthesized images were evaluated through pigment intensity analysis, structural similarity index (SSIM), and dermatologists' blinded assessments, confirming high fidelity to the actual posttreatment images. These results validate the capacity of the model to accurately simulate therapeutic outcomes across diverse treatment modalities. Leveraging these predictive capabilities, we developed a CycleGAN-based visual decision-support system for acne management. During clinical consultations, facial photographs are processed to generate simulated posttreatment images for each therapeutic option, empowering dermatologists to objectively compare outcomes and select optimal interventions. This system aims to facilitate personalized treatment planning, minimize trial-and-error costs for patients, and mitigate the risks of ineffective or excessive therapies.

acne, generative adversarial network, skin diseases, deep learning, AI-assisted medical decision-making

doi: [10.1360/CSB-2025-5076](https://doi.org/10.1360/CSB-2025-5076)