



北京理工大学
BEIJING INSTITUTE OF TECHNOLOGY

2024

德以明理·学以精工

从图像条件生成到CT图像增强应用 From Conditional Image Generation to CT Image Enhancement Applications



BISC



主讲人：付莹教授，陈林蔚

邮箱：{fuying}{chenlinwei}@bit.edu.cn

日期：2025/5/11



2023

德以明理 学以精工

目录

CONTENTS

01 | 研究背景

02 | 图像条件生成技术简述

03 | 从图像生成到CT图像增强

04 | 总结与展望



2023

德以明理 学以精工

目录

CONTENTS

01 | 研究背景

02 | 图像条件生成技术简述

03 | 从图像生成到CT图像增强


04 | 总结与展望

■ CT图像在疾病诊断中的重要性

- 计算机断层扫描（CT）使用X射线和计算机处理技术生成人体内部三维信息的断层图像。
- 医生能够无需切割即可看到获取患者体内结构视图，实现疾病的早期检测、诊断和治疗规划。



CT扫描示意图





从颅底到顶部的正常人脑CT图像，采取静脉注射造影剂。

■ CT图像在疾病诊断中的挑战——造影剂

- 获取清晰的CT图像常常需要使用造影剂，如碘造影剂，以增强血管和组织的可视性。
- 然而，造影剂的使用存在**诸多缺点和不良影响**，例如高成本、过敏反应、肾功能损害等



碘造影剂 是目前影像学诊断与介入治疗领域使用最广泛的造影剂。主要包括：优维显（碘普罗胺）、双北（碘海醇）、泛影葡胺、泛影酸钠、碘化油、碘宁（碘克沙醇）等



颈部淋巴结

普通CT（左图，无造影剂）vs 增强CT（右图，有造影剂）

■ CT图像在疾病诊断中的挑战——辐射暴露


- CT成像过程会对人体产生辐射，长期或过量的辐射暴露可能增加癌症等疾病的风险。
- 但低剂量CT（LDCT）图像信噪比低，容易产生噪声和伪影，降低诊断准确性。



各部位CT检查项目的辐射剂量	
部位	平均剂量 (mSv)
头部	2
鼻窦	2
颈部	3
胸部	6
腹部	8
盆腔	8
腰椎	6
泌尿系CTU	8
冠脉CTA	5-15
颅脑CTA	4
颈部CTA	6
胸腹CTA	15
低剂量胸部	1
低剂量鼻窦	0.6

■ CT图像在疾病诊断中的挑战——病症难诊断

- 部分癌症早期，例如胰腺导管腺癌（PDAC），早期症状不明显，筛查极具挑战性。
- 且由于胰腺位置深且周围结构复杂，早期病灶在CT图像不明显，难以区分。



胰腺位置深且周围结构复杂，易与其它病症混淆

■ 图像生成技术的兴起


- 近年来图像生成技术，生成对抗网络（GANs）在图像生成领域取得了突破性进展。
- GANs通过学习真实数据分布对CT图像进行增强，以解决其看不见、看不清、查不到的难题。

Background removal




by Kaihu Chen

Sketch → Pokemon




by Bertrand Gondouin

Sketch → Portrait




by Mario Klingemann

#fotogenerator



sketch by Yann LeCun

Monet ↔ Photos



Monet → photo





photo → Monet




Photograph

Zebras ↔ Horses




zebra → horse




horse → zebra



Summer ↔ Winter



summer → winter



winter → summer



GANs用于图像生成的示例

2023

德以明理 学以精工

目录

CONTENTS

01 | 研究背景

02 | 图像条件生成技术简述

03 | 从图像生成到CT图像增强

04 | 总结与展望

2. 图像生成技术概述



■ 图像生成——定义和分类

- 图像生成是指利用计算机算法和技术生成全新的图像或修改现有图像的过程。
- 图像生成可以分为文生图、图生图两大类，此处主要讨论图生图。


文生图示例

"A brain riding a rocketship heading towards the moon."



从文字描述到符合描述的图像

图生图示例




从黑白图像到彩色图像

2. 图像生成技术概述



■ 对抗生成网络GAN——从噪声到图像

- GAN (Generative adversarial nets) 是由Ian Goodfellow等人在2014年提出。
- 它包括两个互相对抗的神经网络：生成网络(Generator)和判别网络(Discriminator)。




2. 图像生成技术概述



■ 对抗生成网络GAN——从噪声到图像

- 生成网络G的目标是从噪声中生成尽可能真实的图像。
- 生成网络G的优化目标是 최소화 对抗损失函数，即骗过判别网络D使其认为是真实图片。




2. 图像生成技术概述



■ 对抗生成网络GAN——从噪声到图像

- 判别网络D的目标是尽可能分辨图像质量的好坏。
- D的优化目标是最大化对抗损失函数，即尽可能区分真实图像与生成网络的输出。





2. 图像生成技术概述



■ 条件生成网络CGAN——从无条件到有条件

- CGAN (Conditional GAN) 是GAN的一种改进，由Mehdi Mirza等于2014年提出。
- 相比标准的GAN，增加了条件输入来控制生成结果。





2. 图像生成技术概述



■ 条件生成网络CGAN——从无条件到有条件

- GAN的生成从随机高斯噪声得来，具有随机性，无法直接稳定得到预期生成结果。
- CGAN通过控制附带条件，可以更加精确地生成我们期望的生成样本。




2. 图像生成技术概述



■ pix2pix——从图像到图像

- pix2pix 是一种基于条件生成对抗网络(CGAN)的生成模型，由 Phillip Isola等于2017年发表。
- 它可以在成对的输入输出图像上进行监督式学习，学习从两类不同图像的映射关系。



2. 图像生成技术概述




■ pix2pix——从图像到图像

- pix2pix 除了使用了标准的GAN 损失函数训练，还同时使用了 L1 损失函数。
- 前者提高生成图像的整体逼真性，后者促进生成与真实图像细节相似的结果。



L1损失函数与GAN损失函数作用




Encoder-decoder 对比 U-Net

2. 图像生成技术概述




■ pix2pix——从图像到图像

- pix2pix 采用了U-Net结构，增加了跳层链接将Encoder浅层特征联接到Decoder中。
- 在生成图像中，相比之前普遍使用的Encoder-decoder结构更能生成良好的细节。



L1损失函数与GAN损失函数作用




Encoder-decoder 对比 U-Net

2. 图像生成技术概述



■ pix2pix——从图像到图像

- pix2pix实现了通用性强的图像到图像的转换生成，可以应用于多种图像转换任务。
- 例如草图到照片、灰度图到彩色图、边缘图到实物图等，取得图像质量良好的生成效果。




2. 图像生成技术概述



■ pix2pix——从图像到图像

- pix2pix采用监督式学习完成模型训练，依赖成对图像作为训练数据学习图像到图像的转换关系
- 用于监督式学习的成对图像难以收集，训练数据质量要求高，导致应用成本较高。




2. 图像生成技术概述



■ CycleGAN——从有监督到无监督

- CycleGAN 是一种无监督的图像到图像转换模型，由 Jun-Yan Zhu 等于 2017 年提出。
- 它的目标是在没有成对输入输出图像的情况下，学习从一个图像域到另一个图像域的转变。




2. 图像生成技术概述



■ CycleGAN——从有监督到无监督

- CycleGAN引入了**循环一致性**损失，确保输入图像经过正向转换和逆向转换后能重建原始图像。
- 即一张A域图片变换到B域后，再从B域变换回A域的结果要与原始图像尽可能一致。




2. 图像生成技术概述




■ CycleGAN——从有监督到无监督

- CycleGAN不需要成对的图像训练，而是使用两个独立的图像集作为训练数据。
- 相比pix2pix 依赖成对的输入输出图像作为训练数据，这大大降低了数据收集的难度。



配对与非配对数据




CycleGAN实现高质图像风格迁移

2. 图像生成技术概述



■ CycleGAN——从有监督到无监督

- CycleGAN 循环一致性的特性可以同时学习两个图像域之间的双向转换关系。
- 通过一次训练即可得到A域→B域， B域→A域两个图像生成模型。



2023

德以明理 学以精工

目录

CONTENTS

01 | 研究背景

02 | 图像条件生成技术简述

03 | 从图像生成到CT图像增强


04 | 总结与展望

3. 从图像生成到CT图像增强




■ 基于GAN的无造影主动脉与颈动脉CT血管成像

- CT 血管造影 (CTA) 是一种无创且有效的血管成像技术，广泛用于诊断血管病变。
- 但其需要使用碘造影剂 (ICA) ，这对碘过敏、肾功能不全或多发性骨髓瘤患者存在风险。



无造影剂图像 NCCT
(Non-Contrast CT)




有造影剂图像 CTA
(CT angiography)

3. 从图像生成到CT图像增强




■ 基于GAN的无造影主动脉与颈动脉CT血管成像

- 问题：如何避免 ICA 的潜在风险和成本，寻找替代方法从NCCT获取高质量的 CTA 图像？



无造影剂图像 NCCT
(Non-Contrast CT)




有造影剂图像 CTA
(CT angiography)

3. 从图像生成到CT图像增强



■ 基于GAN的无造影主动脉与颈动脉CT血管成像

- 提出方法：利用GAN技术实现图像增强**CTA-GAN**框架，避免使用造影剂实现清晰血管成像。
- 效果：实现将无对比增强CT（NCCT）图像转变为高质量合成CTA（Syn-CTA）图像。




3. 从图像生成到CT图像增强



■ 基于GAN的无造影主动脉与颈动脉CT血管成像

- 组件：CTA-GAN生成器G，用于从NCCT图像中合成血管清晰的CTA图像。
- 效果：其将归一化的无对比增强CT（NCCT）图像作为输入，输出归一化的Syn-CTA图像。

CTA-GAN 生成器



生成器G：


- 输入为NCCT图像 x
- 输出为Syn-CTA图像 $G(x)$
- 采用Encoder-Decoder架构

3. 从图像生成到CT图像增强



■ 基于GAN的无造影主动脉与颈动脉CT血管成像

- 组件：CTA-GAN 校正器C，用于对齐合成的Syn-CTA图像与真实CTA图像。
- 效果：将真实CTA图像调整到Syn-CTA空间，以便更准确地计算误差损失，优化生成器。




3. 从图像生成到CT图像增强



■ 基于GAN的无造影主动脉与颈动脉CT血管成像

- 组件：CTA-GAN 判别器D，区分真实的CTA图像和生成的Syn-CTA图像。
- 效果：通过对抗损失（adversarial loss）来训练生成器，使生成器生成的图像更加真实。



3. 从图像生成到CT图像增强



■ 基于GAN的无造影主动脉与颈动脉CT血管成像

- 量化评估：对比不同模型pix2pix、RegGAN合成的CT血管造影图像进行定量评估。
- 结果：提出的CTA-GAN在各种量化指标上包括NMAE、PSNR以及SSIM取得最佳的效果。

Model	Internal Validation Set			Internal Test Set			External Validation Set		
	NMAE	PSNR	SSIM	NMAE	PSNR	SSIM	NMAE	PSNR	SSIM
pix2pix	0.026	25.30	0.843	0.026	25.19	0.797	0.026	24.96	0.784
RegGAN	0.013	31.05	0.924	0.014	30.10	0.890	0.015	29.86	0.883
CTA-GAN	0.010	33.76	0.948	0.011	32.07	0.919	0.013	31.58	0.906


NMAE = 标准化平均绝对误差 (normalized mean absolute error) PSNR = 峰值信噪比 (peak signal-to-noise ratio)
SSIM = 结构相似性指数 (structural similarity index measure)

3. 从图像生成到CT图像增强



■ 基于GAN的无造影主动脉与颈动脉CT血管成像

- 可视化评估：对比不同模型pix2pix、RegGAN合成的CT血管造影图像进行可视化评估。
- 结果：提出的CTA-GAN有效地从NCCT图像中得到了最接近使用造影剂的CTA结果。




3. 从图像生成到CT图像增强




■ 基于深度学习实现大规模无造影CT胰腺癌检测

- 背景：胰腺导管腺癌（PDAC）死亡率高，早发现至关重要，但目前没有可行的大规模筛查手段。
- 问题：NCCT广泛应用，辐射剂量低，具有大规模筛查的潜力，如何利用NCCT实现筛查？



1990年与2017年中国各年龄组胰腺癌发病率




1990年与2017年中国各年龄组胰腺癌死亡率

3. 从图像生成到CT图像增强



■ 基于深度学习实现大规模无造影CT胰腺癌检测

- 提出方法：PANDA (Pancreatic Cancer Detection with AI) 胰腺癌早期检测的深度学习模型。
- 效果：通过非对比度NCCT图像实现高准确度的胰腺病变检测和分类。



PANDA包括三个阶段：

- 第一阶段：胰腺定位
- 第二阶段：胰腺病变区域检测
- 第三阶段：胰腺病变进行鉴别诊断


3. 从图像生成到CT图像增强



■ 基于深度学习实现大规模无造影CT胰腺癌检测

- 第一阶段：胰腺定位，在NCCT图像中找出胰腺所在的区域。
- 使用 nnU-Net 模型密集逐像素对NCCT图像内容分类，从而完成胰腺定位。

PANDA-阶段一




3. 从图像生成到CT图像增强



■ 基于深度学习实现大规模无造影CT胰腺癌检测

- 第二阶段：进行胰腺病变区域检测，从阶段一中的胰腺区域中找出病变区域。
- 训练多任务卷积神经网络捕捉胰腺病变细微纹理变化，预测病变概率以及检测病变区域。




3. 从图像生成到CT图像增强



■ 基于深度学习实现大规模无造影CT胰腺癌检测

- 第三阶段：如果第二阶段预测病变概率达到阈值，则对胰腺病变进行细粒度鉴别诊断。
- 整合辅助记忆 Transformer 来自动编码胰腺病变的特征原型，得到诊断结果。




3. 从图像生成到CT图像增强




■ 基于深度学习实现大规模无造影CT胰腺癌检测

- 来自上海市胰腺疾病研究所的 291 例患者进行了独立内部评估。
- PANDA检测的精确率 ($= \frac{\text{正确诊断}}{\text{误诊} + \text{正确诊断}}$) 达到了为92.9%。召回率 ($= \frac{\text{正确诊断}}{\text{漏诊} + \text{正确诊断}}$) 达到了99.9%。



a、PANDA与33名具有不同专业水平的读者在非对比度CT上进行病变检测的比较。




b、同一组读者在非对比度CT上在PANDA的辅助下进行病变检测的性能

3. 从图像生成到CT图像增强




■ 基于深度学习实现大规模无造影CT胰腺癌检测

- PANDA 在胰腺病变检测和 PDAC 鉴别诊断表现均显著优于专家阅片的平均水平。
- 其中精确率和召回率较医生阅片分别高出 14.7%和 6.8%



a、PANDA与33名具有不同专业水平的读者在NCCT上进行病变检测的比较。PANDA高于专家平均水平。




b、同一组读者在NCCT上在PANDA的辅助下进行病变检测的性能。PANDA辅助可以提高专家平均水平。

3. 从图像生成到CT图像增强



■ 基于深度学习实现大规模无造影CT胰腺癌检测

此外，研究的 1 个月冷却期后，阅片医生在得到 AI 辅助后阅片水平进一步提高。



2023

德以明理 学以精工

目录

CONTENTS

01 | 研究背景

02 | 图像条件生成技术简述

03 | 从图像生成到CT图像增强

04 | 总结与展望

■ 总结

在医疗影像领域，CT图像在疾病诊断中发挥着至关重要的作用。然而，传统CT成像技术面临着许多挑战，包括对造影剂的依赖、辐射暴露风险以及难以早期发现某些癌症等问题。近年来，深度学习技术，尤其是生成对抗网络（Generative Adversarial Networks, GANs）的快速发展，为解决这些问题提供了创新的解决方案。

- **从看不见到看见**：利用无造影剂CT图像生成高质量CT图像，能够从无造影剂CT图像生成具有造影剂效果的高质量图像，减少对造影剂的依赖，降低患者风险。
- **从看不清到看清**：低剂量CT图像增强，能够显著提高低剂量CT图像的质量，同时减少辐射暴露，保证诊断的准确性。
- **从查不到到查到**：早期癌症检测，通过增强CT图像并结合多种深度学习技术，可以提高早期癌症的检测率和诊断准确性。

■ 展望

展望未来，以图像生成技术为代表的深度学习技术将在CT图像增强和疾病诊断中的应用将继续深化和扩展，主要表现在以下几个方面：

- **扩散模型**（ Diffusion Models ）作为一种新兴的生成模型，在医学影像处理中的潜力也不容忽视，其在图像生成质量和多样性方面表现出色，未来可能在CT图像增强和去噪中发挥重要作用。
- **多模态融合**：探索将不同类型的医学影像数据（ CT、MRI、PET等 ）融合到生成模型中，以提供更加全面和准确的诊断信息。
- **智能辅助诊断**：结合GANs与其他深度学习技术，开发智能辅助诊断系统，实现自动化病灶识别和标注，减少人为误差，提升诊断准确性和效率。

■ 感谢关注北京理工大学ISP实验室：<https://ying-fu.github.io/>



付莹

北京理工大学
教授、博导

- 2017年入选国家级高层次人才计划
- 曾获得ICML 2020, PRCV 2019最佳论文奖




邹云昊-博士研究生

- 图像去噪、高动态范围成像、计算摄影学



陈林蔚-博士研究生

- 图像分割、目标检测、遥感、图像生成



张帆-博士研究生

- 暗光增强、图像去雨、水下深度估计



梁瑛平-博士研究生

- 目标检测、光流估计、3D计算机视觉



张英凯-博士研究生

- 高光谱成像、图像超分辨率、曝光校正



欢迎扫描二维码
关注团队工作进展

北京理工大学ISP实验室技术积累

问题建模

$$\text{CT图像增强优化建模 } \hat{O} = \underset{O}{\operatorname{argmin}} D(O) + \lambda R(O)$$

保真项 $D(O)$

确保重建图像 O 满足成像物理模型



先验项 $R(O)$

确保重建图像 O 真实性

解决方案

基于即插即用先验的CT图像增强

$$(\hat{O}, \hat{V}) = \underset{O, V}{\operatorname{argmin}} \frac{1}{2} \|O - V\|^2 + \lambda R(V)$$

subject to $PO = S$


P : 测量矩阵 S : 单像素测量值

$$O^{k+1} = V^k + P^T (PP^T)^{-1} (S - PV^k)$$

$$V^{k+1} = \mathcal{D}_\sigma(O^{k+1})$$

$\mathcal{D}_\sigma$: 各种先进的图像去噪算法

监督与无监督联合的CT图像增强



监督学习阶段

无监督学习阶段


单像素测量值

重建图像

测量矩阵

单像素成像物理模型的约束 & 全变分正则化约束

基于Transformer网络的CT图像增强



基于深度展开网络的CT图像增强

