



计算机科学

COMPUTER SCIENCE

基于颜色流模型的非配对医学图像颜色迁移方法

王晓洁, 刘尽华, 陆书一, 周元峰

引用本文

王晓洁, 刘尽华, 陆书一, 周元峰. [基于颜色流模型的非配对医学图像颜色迁移方法](#)[J]. 计算机科学, 2024, 51(8): 176-182.

WANG Xiaojie, LIU Jinhua, LU Shuyi, ZHOU Yuanfeng. [Color Transfer Method for Unpaired Medical Images Based on Color Flow Model](#) [J]. Computer Science, 2024, 51(8): 176-182.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[基于非线性交通流模型的交通子区边界控制策略研究](#)

Traffic Subarea Boundary Control Strategy Based on Nonlinear Traffic Flow Model

计算机科学, 2024, 51(6A): 230900016-7. <https://doi.org/10.11896/jsjcx.230900016>

[基于Grover算法的图着色问题求解](#)

Solving Graph Coloring Problem Based on Grover Algorithm

计算机科学, 2023, 50(6): 351-357. <https://doi.org/10.11896/jsjcx.220400051>

[基于李雅普诺夫优化的移动群智感知在线任务分配策略](#)

Online Task Allocation Strategy Based on Lyapunov Optimization in Mobile Crowdsensing

计算机科学, 2023, 50(2): 50-56. <https://doi.org/10.11896/jsjcx.221100179>

[图着色问题禁忌搜索改进算法](#)

Improved Algorithm for Tabu Search of Graph Coloring Problems

计算机科学, 2022, 49(11A): 211000128-5. <https://doi.org/10.11896/jsjcx.211000128>

[一种基于节点稳定性和邻域相似性的社区发现算法](#)

Community Detection Algorithm Based on Node Stability and Neighbor Similarity

计算机科学, 2022, 49(9): 83-91. <https://doi.org/10.11896/jsjcx.220400146>

基于颜色流模型的非配对医学图像颜色迁移方法

王晓洁 刘尽华 陆书一 周元峰

山东大学软件学院 济南 250101

(wxj_811@163.com)

摘要 在临床应用中,CT 图像是一种比较容易获取的影像数据,但是其与真实人体色彩有较大差距。人体断层彩色图像是真实人体的色彩反应,但却是一种稀有数据。如果将两者结合,使得每个病例都可以得到自己的彩色 CT 数据,将会对医生手术和患者理解有更好的促进作用。因此,文中提出了一种基于颜色流模型的医学图像颜色迁移框架。首先,将 CT 数据和真实人体彩色数据分别输入颜色流模型中,提取二者的内容特征和颜色特征;然后,在特征层面进行颜色和纹理的迁移工作;最后,将处理以后的特征信息重新输入到可逆颜色流模型中进行图像重建工作。为了使着色以后的图像更具有纹理特征,在每个流模块之后添加了纹理约束损失;同时,为了保证医学图像上细小血管等组织的特征不被丢失,在着色图像和源图像之间添加了边缘约束损失。通过定性和定量实验证明,所提方法比其他的着色方法更加鲁棒,且着色后的图像更加真实。文中也在不同的数据域上进行了测试,依旧可以得到稳定的实验结果。同时,所提方法也可以在不调整窗宽/窗位的前提下显示清晰的组织结构。

关键词:流模型;着色;纹理约束;稳定性;边缘约束

中图分类号 TP391.41

Color Transfer Method for Unpaired Medical Images Based on Color Flow Model

WANG Xiaojie, LIU Jinhua, LU Shuyi and ZHOU Yuanfeng

School of Software, Shandong University, Jinan 250101, China

Abstract In clinical applications, CT image is a kind of image data that is relatively easy to obtain, but there is a large gap between them and the real human body color. The tomographic color image of the human body is the color response of the real human body, but it is a rare data. Combining the two, so that each case can get its own color CT data, which will have a effect on the doctor's surgery and the patient's understanding to the disease. Therefore, this paper proposes a medical image colorization framework based on a color flow model. It first inputs the CT and human color data into the color flow model and extracts the content and color features. Then, the color and texture transfer work is performed at the feature level. Finally, the processed feature information is re-input into the reversible color flow model for image reconstruction. After each flow module, we add a texture constraint loss to make the shaded image more textured. At the same time, we add edge constraints to ensure that the characteristics of small blood vessels and other tissues on the medical image are not lost. Qualitative and quantitative experiments prove that our method is more robust than other colorization methods, and the experimental results are more realistic. And we conduct extensive experiments on different data domains, proving that our method is not affected by domain shift and can obtain stable experimental results. At the same time, the proposed method can display a clear organizational structure without adjusting the window width/level.

Keywords Flow module, Colorization, Texture constraint, Stability, Edge constraint

到稿日期:2023-07-12 返修日期:2023-11-15

基金项目:战略性国际科技创新合作专项国家重点研发计划(2021YFE0203800);国家自然科学基金浙江省信息化与工业化融合联合基金(U1909210);国家自然科学基金(62172257)

This work was supported by the National Key R&D Plan on Strategic International Scientific and Technological Innovation Cooperation Special Project(2021YFE0203800), NSFC-Zhejiang Joint Fund of the Integration of Informatization and Industrialization(U1909210) and National Natural Science Foundation of China(62172257).

通信作者:周元峰(yfzhou@sdu.edu.cn)

1 引言

灰度图是医学图像的主要表现形式,其优点是可以呈现组织的横断面图像,并且具有无创性。但是由于灰度医学图像的呈现形式与真实人体的色彩差距较大,医生术前和术中强烈的视觉反差,会对手术造成一定的误差。如果可以给予医学图像真实的人体色彩,增强医生在手术中的直观感受,有利于其正确地判断观察手术位置,提高手术的成功率。另外,灰度医学图像对于没有任何专业背景的病患来说是很难理解的,这可能会给医患沟通带来一些麻烦。而人体彩色图像具有真实的人体器官色彩表示,能够使得没有任何专业背景的人也可以清晰地分辨出各个器官组织。如果我们将两种数据合成成为一种具有真实人体器官组织色彩的 CT 图像,将为医患沟通带来更有利的影响。

关于医学图像着色问题,已经有研究者进行了很多的尝试。Welsh 等^[1]将真实人体彩色图像的颜色块迁移到医学图像中。但是这种颜色迁移的方法没有考虑到图像中的纹理信息,以致于着色结果缺乏真实感。Khan 等^[2]构建了彩色图像的颜色查找表,对内窥镜图像进行着色。该方法的难点在于需要寻找与医学图像完全配对的彩色图像,这在实际应用中是无法做到的。随着深度学习的不断发展,利用深度学习网络进行医学图像着色的工作也层出不穷。Mathur 等^[3]利用生成网络进行颜色迁移,并使用彩色图像作为参考图像。以上方法都能快速得到着色后的医学图像,但是其局限性在于会出现错误着色的情况。尤其是医学图像中比较细小的血管组织,着色后会出现组织丢失、细节模糊等问题,这会严重影响医生的判断,对患者造成误导。

本文吸取前人的经验,利用深度网络进行彩色图像和 CT 图像之间颜色和纹理的迁移工作。为了保证生成图像的内容不发生泄露,受 An 等提出的 ArtFlow 模型^[4]的启发,本文利用流模型实现内容无损失的颜色迁移工作。同时,为了使得着色后的图像更具有真实感,本文还添加了纹理迁移约束。由于医学图像需要更加严谨的着色结果,例如细小血管等需要在着色后还能有良好的视觉效果,我们添加了边缘约束操作。定性和定量的实验表明,本文方法都取得了较好的实验结果。

本文的创新点总结为:

- 1) 利用流模型对医学 CT 图像进行颜色迁移工作,保证了生成图像的内容和几何结构信息在着色前后不发生变化。
- 2) 在每一个流模块之后添加格拉姆损失来约束图像的生成细节,使得着色后图像能够带有彩色图像的组织纹理信息。
- 3) 在保证着色后医学图像的内容不扭曲的情况下,还需要保证医学图像上细小特征的清晰度。因此,本文在着色后图像和源医学图像之间添加了边缘约束项来保证细节特征不丢失。
- 4) 本文进行了定性和定量的比较,并且在不同的数据域上进行了测试,均取得了较好的实验结果,证明了所提方法的稳定性和可行性。

2 相关工作

2.1 流模型

流模型 (Flow-based Model) 是生成模型 (Generative Model) 的一种,它在一组可逆变换中建立目标分布与源分布之间的映射关系。与之有相同功能的另一种生成模型 GAN^[5] (Generative Adversarial Network) 已经被用于多种视觉任务中,而对流模型的关注相对更少。流模型使用可逆神经网络 f_θ 来参数化一个复杂分布 $p_y(y|\theta)$ 。而 f_θ 将从简单分布 (例如高斯分布) 中采样,并进行函数映射 $y = f_\theta^{-1}(z)$ 。因此,可以通过随机梯度下降的方法来直接最小化负对数似然方程以进行网络训练。

流模型 NICE 最初是由 Dinh 等^[6]提出的。后来 Dinh 等^[7]又在此基础上做了改进,提出了 RealNVP 模型。本文使用的 Glow 模型^[8]基本沿用了 RealNVP 的网络架构,并对其做了简化和规范。最近几年有很多基于流模型的工作,例如点云生成^[9-11]和分类^[12]、图像生成^[13-14]和图像超分辨率^[15]等。其中, Ardizzone^[13]和 Winkler 等^[14]还修改了 Glow 架构,通过在放射耦合层中串联条件变量进行图像生成任务。

2.2 颜色纹理迁移

颜色迁移的目的就是将一幅图像的颜色信息迁移到另一幅图像中,其与风格迁移任务有很多相似之处。许多研究者也在风格迁移任务中得到启发,并将其应用到医学图像着色的工作中。Gatys 等^[16]首先利用 VGG 网络将参考图像的风格迁移到源图像中。但是此方法的局限性在于风格迁移以后的图像几何结构产生较大的扭曲变形,真实感不强。因此 Luan 等^[17]在此基础上提出了真实感风格迁移的方法,使得风格化以后的图像能够保留源图像的几何结构。随着生成对抗网络 (Generative Adversarial Network, GAN) 的流行,基于 GAN 的风格迁移方法也取得了很好的结果。例如, Isola 等^[18]利用条件 GAN 网络实现了配对数据集之间的风格迁移。Zhu 等^[19]又在此基础上利用循环一致性生成对抗网络,实现了非配对数据集之间的风格转换。除此之外,标准化流模型 (Normalization Flow) 也陆续被应用在风格迁移工作中,如基于流模型的无偏风格迁移方法 ArtFlow。Ardizzone 等^[13-14]也将流模型应用到图像生成的任务中。最近流行的扩散模型^[20-21] (Diffusion Model) 也在风格迁移任务中做了很多工作。

3 本文方法

3.1 方法概述

本章将详细阐述基于颜色流框架下的医学图像着色方法。本文方法所需要的两个输入分别为 CT 图像数据 $x_c \in \mathcal{X}_c$ 和彩色人体切片数据 $x_s \in \mathcal{X}_s$, 如图 1 所示。我们将 CT 图像 x_c 和彩色图像 x_s 分别经过颜色流模块编码成内容特征 f_c 和风格特征 f_s 。然后,利用 AdaIN 模块进行医学图像着色工作,得到着色后的特征 f_{cs} 。最后,将颜色迁移后的特征 f_{cs} 重新输入颜色流模型,利用流模型的可逆性, f_{cs} 最终会重建成

彩色 CT(x_{cs})。为了能够让着色后的图像带有真实图像的纹理特征,本文在每个流模块后添加格拉姆约束。最后,为了不丢失医学图像的细节信息,并保证着色后 CT 图像几何结构的准确性,本文在生成图像和源图像之间加入边缘约束模块。

3.2 颜色流模型

医学图像着色任务与自然图像的风格迁移任务有很多相似之处。最常用的风格迁移方法是利用生成模型分别对源图像和风格图像进行特征编码,然后使用解码器将特征进行

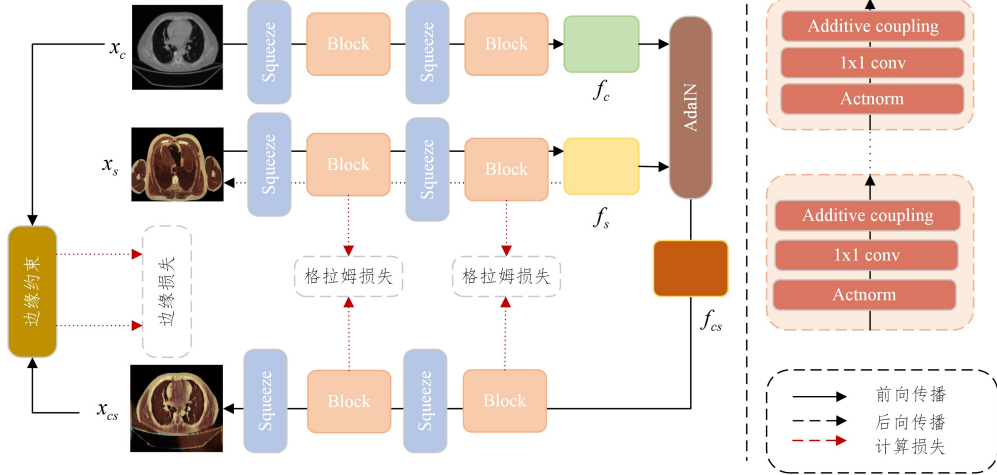


图1 本文算法的结构

Fig. 1 Overall structure of the proposed algorithm

如图1所示,将CT图像和人体彩色图像分别输入颜色流网络进行内容和风格的编码,将得到的特征进行着色变换后再重新输入颜色流网络进行重建。本文的网络模型由多个Squeeze层和流模块组成。Squeeze层的作用是增加通道轴的维度,但依然保留局部相关性。每个流模块的详细架构如图1右半部分所示,每个块由8个Flow模块组成,每个Flow模块是由一个Actnorm层、一个 1×1 卷积层和一个加性耦合层组成。

下文将详细描述这3个部分。

Actnorm是在Glow中提出的,用于取代BN层^[23],是NICE中尺度变换层的一般化表示,其计算式如下:

$$\mathbf{x}' = \frac{\mathbf{x} - \mu}{\sigma} \quad (1)$$

其中, μ 和 σ 都是可训练参数,并且是用初始batch的均值和方差去初始化; x 表示输入。

Invertible 1×1 convolution可逆 1×1 卷积是对置换操作的一般化。在流模型中,将各个维度打乱重新排列是较为重要的一步,NICE方法采用的是最简单的反转操作,而RealNVP是随机打乱。Glow模型中采用的是将置换矩阵转换成一般的可训练的参数矩阵的方式。我们可以直接写出变换为:

$$\mathbf{x}'' = \mathbf{x}' \log |\det \mathbf{W}| \quad (2)$$

其中, \mathbf{W} 是一个大小为 $c \times c$ 的雅可比矩阵; c 是张量 \mathbf{x}' 和 \mathbf{x}'' 的通道维度。对于 \mathbf{W} 的求解,Glow^[8]的解决方案是利用LU分解的逆运用。将 \mathbf{W} 分解为:

$$\mathbf{W} = \mathbf{P}\mathbf{L}\mathbf{U} \quad (3)$$

重建。不管是变分自编码器(VAE)^[22]还是生成对抗网络(GAN),都会出现内容泄露问题。ArtFlow已经证明发生内容泄露的原因是编码器重建错误和有偏的编码训练。而在医学图像翻译领域,我们应该保证翻译后图像的准确性。翻译后的医学图像如果出现了器官组织或者结扭曲,则都是不准确的,且不具有临床意义。受到ArtFlow工作的启发,本文利用标准化流模型作为着色基础架构网络,并在此基础上做了相关优化,解决了医学图像结构扭曲的问题。

其中, \mathbf{P} 是一个置换矩阵, \mathbf{L} 是一个下三角阵, \mathbf{U} 是一个上三角阵。然后,固定 \mathbf{P} 和 \mathbf{U} 的对角线的正负号,优化训练 \mathbf{L} 和 \mathbf{U} 的其余参数。

Additive coupling为了解决流模型中行列式计算比较困难的问题,在NICE中提出了加性耦合层。将 d 维的 \mathbf{x}'' 分为两部分,即 x_1'' 和 x_2'' ,然后进行下列变换:

$$\begin{aligned} h_1 &= x_1'' \\ h_2 &= x_2'' + \mathbf{M}(x_1'') \end{aligned} \quad (4)$$

其中, \mathbf{M} 是任意函数,按照上述公式进行变换后,可以将 \mathbf{x}'' 的各个维度进行重排。变换后的 h 是一个三角阵,这样就解决了行列式的计算问题。同时式(4)的逆变换为:

$$\begin{aligned} x_1'' &= h_1 \\ x_2'' &= h_2 - \mathbf{M}(h_1) \end{aligned} \quad (5)$$

3.3 纹理生成

我们发现,经过颜色流模型之后,生成的彩色CT并没有充分学习到人体彩色图像的纹理信息。着色后的图像也表现为比较暗淡的颜色特征,与真实图像差距较大。受Li等^[24-26]工作的启发,一系列的格拉姆矩阵可以提供纹理的静态描述。因此,我们尝试对着色的CT图像和彩色图像使用格拉姆矩阵来保证其纹理的生成。不同于卷积神经网络在每一层后面加格拉姆损失,本文是在每个流模块之后添加格拉姆约束,使其能够在特征层面上进行纹理的计算,更加严格地约束了纹理特征的准确性。如图1所示,在风格图像和彩色图像的重建过程中,在每个流模块之后加入格拉姆损失计算。具体计算式如下:

$$L_g = \| \mathbf{G}_{\text{stylized}} - \mathbf{G}_{\text{style}} \|_1 \quad (6)$$

$$G_{ij} = \sum_n (\mathbf{F}_{in} - \bar{\mathbf{F}})(\mathbf{F}_{jn} - \bar{\mathbf{F}})$$

其中, $\mathbf{G}_{\text{stylized}}$ 和 $\mathbf{G}_{\text{style}}$ 分别代表着色后的特征和彩色人体图像的格拉姆矩阵。 \mathbf{F}_{in} 和 \mathbf{F}_{jn} 代表位置 n 处的第 i 个和第 j 个滤波器处的矢量化激活 (Vectorized Activations)。 $\bar{\mathbf{F}}$ 定义为网络当前层中所有激活的平均值。

3.4 边缘约束

加入格拉姆损失可以使着色后的 CT 图像拥有更加真实的纹理信息。但是人体中比较细小的部位可能会变得模糊, 如结节的边缘在着色后会产生较大变化。在临床上, 有经验的医生一般会根据病灶的边缘是否规则来判断疾病的严重程度。因此, 保证着色后图像的边缘特征也是本文的重要任务之一。由此, 可以通过提取生成图像的边缘特征, 并计算其与源图像边缘特征的偏移量来约束其准确性。本文采用 L_1 距离损失函数来约束其边缘特征, 计算式如下:

$$L_{\text{edge}} = \| \phi(x_c) - \phi(x_{st}) \|_1 \quad (7)$$

其中, ϕ 是边缘提取网络, x_c 代表 CT 图像, x_{st} 代表着色以后的 CT 图像, $\| \cdot \|_1$ 表示 L_1 距离度量。

3.5 内容和风格损失

1) 内容损失。为了使生成图像和医学图像的高维信息更加接近, 保证其生成图像内容的准确性, 我们利用特征提取网络分别提取医学图像和着色后的彩色图像的内容特征, 计算其内容相似度。其计算式如下:

$$L_{\text{con}} = \| F(x_c) - F(x_{st}) \|_2 \quad (8)$$




图 2 实验结果的对比

Fig. 2 Comparison of experimental results

本文方法包含两个 Blocks, 每个 Block 包含 8 个神经流。每个神经流包含一个 Actnorm 层、一个可逆 1×1 卷积层和一个加性耦合层。整个网络是基于 pytorch 框架的。使用 Adam 优化器迭代 20 000 次, 批处理大小为 1, 学习率为 1×10^{-4} 。在 RTX 3090Ti GPU 上, 训练时间大约需要 8h。

4.2 衡量标准

SSIM (Structrual Similarity Index Metric)^[29]: 用于评估两幅图像之间的结构相似水平。

PSNR (Peak Signal to Noise Ration)^[30]: 用于评价噪声水平或图像失真的客观评价指标。

巴氏距离 (Bhattacharyya Distance)^[31]: 用于测量两种离散概率分布的可分离性。在直方图相似度计算时, 巴氏距离获得的效果最好, 是衡量颜色相似度的主要度量标准。

直方图相关性 (Histogram Correlation)^[32]: 将两幅图像

其中, F 代表特征提取网络, 它是由卷积层和激活层组成; $\| \cdot \|_2$ 表示 L_2 距离度量。

2) 风格损失。为了使生成图像在颜色上更加接近真实人体彩色图像, 我们同样利用了内容损失中的特征提取网络对生成图像和真实人体彩色图像进行特征相似度度量。我们将特征提取网络分成 4 个部分 $F = \{f_i | i=1, 2, \dots, n\}$, 并对每一部分的输出特征分别进行相似度度量。其计算式如下:

$$L_{\text{sty}} = \sum_{i=0}^n \| f_i(x_{st}) - f_i(x_s) \|_2 \quad (9)$$

其中, n 的大小为 4, x_s 表示真实人体彩色图像。

因此, 总的损失函数为:

$$L = \lambda_1 L_{\text{con}} + \lambda_2 L_{\text{sty}} + \lambda_3 L_{\text{edge}} + \lambda_4 L_g \quad (10)$$

4 实验比较

4.1 数据集和实验细节

本文实验的数据集有两种: 人体彩色图像数据集^[27]和肺部 CT 数据集。肺部 CT 数据包含带有肺部结节病灶的公开数据集 LIDC-IDRI^[28]和正常肺部的私有数据集。其中彩色数据集包含男性和女性共 1975 张 24 位躯干图像, 分辨率为 2018×216 。LIDC-IDRI 数据集共收录了 1018 个研究实例, 图像类型包括 CT 数据和 X 光片, 是肺部结节公开数据集。正常肺部数据集来自于两个不同的数据中心, 中心 1 数据集包含 20 个肺部正常病例, 中心 2 数据集包含 18 个正常肺部病例。本文使用彩色图像的肺部数据作为训练的参考数据集。在训练过程中, 统一把图像大小设定为 512×512 。

的颜色分布直方图进行相关性比较, 如果有极高的相似度, 那么证明图像是相似的。

4.3 定性和定量对比

本文在肺部 CT 数据集上与不同的着色方法进行了定性和定量结果对比, 并且所有 CT 数据集都是在原始窗宽窗位下进行着色。对比方法包括: 1) 脑部核磁图像着色方法^[3], 该方法将医学图像转换为光学图像, 然后利用自然图像风格迁移方法^[16]进行颜色迁移; 2) 真实感风格迁移方法^[17], 该方法在经典自然图像风格迁移方法^[16]上进行了真实感提升, 使得生成图像更逼真; 3) 基于 CycleGAN 的图像迁移方法^[33], 其在人脸翻译中取得了较为逼真的实验结果, 本文方法也与其进行了实验结果的对比; 4) 基于流模型 (见文献[4]) 的风格迁移方法; 5) CycleGAN^[19], 是非常经典的非配对数据风格迁移方法, 与本文的任务较为相似, 因此也将其加入对比方法中。

定性实验结果对比如图 2 所示,文献[3]中的方法生成的图像色彩过于鲜艳,与真实图像差距较大。经过文献[17]中的方法着色后的 CT 图像艺术感太强,缺乏真实人体图像的纹理信息,已经无法识别细小的血管组织。文献[4]中的方法可以实现颜色的自然迁移,但是会丢失细小组织结构,纹理细节保持得并不好。文献[19]中的方法可以将彩色图像的颜色进行比较准确的迁移,但是产生了严重的结构扭曲。文献[33]中的方法生成的彩色图像产生了错误的纹理特征,并且真实感不够。本文方法不仅能够保持真实感,还能够保证着色后细小组织的准确性,不产生细节丢失问题。

本文还展示了着色后 CT 图像的冠状面、矢状面和横断面的着色结果与原始 CT 图像三视图的对比(见图 3)。从图中可以看出,本文方法可以使图像整体变得很清晰,血管和各种细小分支也能很明显地看到。




图 3 三视图结果

Fig. 3 Three view results

表 1 列出了 LIDC-IDRI 数据集上着色结果的定量对比。PSNR 和 SSIM 的衡量指标上,由于 cycleGAN 的结果已经严重扭曲变形,不具有对比意义,因此只比较了其他几种方法。本文方法的 PSNR 指标比文献[17]中的方法提高了 0.74,本文方法的 SSIM 指标也是最接近原始 CT 结构的。巴氏距离越小,代表图像越相似,本文结果明显优于其他几种着色方法。在直方图相关性的比较中,本文方法也比次优的文献[17]中的方法提升了 10%。

表 1 在 LIDC-IDRI 上不同方法的定量对比结果

Table 1 Quantitative comparison results of different methods on LIDC-IDRI

	文献[4] 中的方法	文献[17] 中的方法	文献[19] 中的方法	文献[3] 中的方法	文献[33] 中的方法	本文 方法
PSNR \uparrow	7.44	8.09	—	11.13	7.91	11.88
SSIM \uparrow	0.63	0.40	—	0.47	0.44	0.67
BD \downarrow	0.52	0.45	—	0.70	0.62	0.39
CORR \uparrow	0.44	0.74	—	0.80	0.67	0.91

4.4 鲁棒性分析

域偏移问题是困扰医学图像处理的一个重要难题,需要测试数据集和训练数据集都在相同的数据域上才会有较好的测试结果。如果出现域偏移情况,则很多方法会失效。而本文方法对不同设备采集的 CT 数据也有较好的鲁棒性。如图 4 所示,分别在 3 个不同的数据域上进行了实验。LIDC-IDRI 数据对比度整体较低,但是本文方法依旧取得了很好的实验结果。在中心 1 数据集和中心 2 数据集上,本文实验

结果依旧有良好的纹理信息和颜色分布。

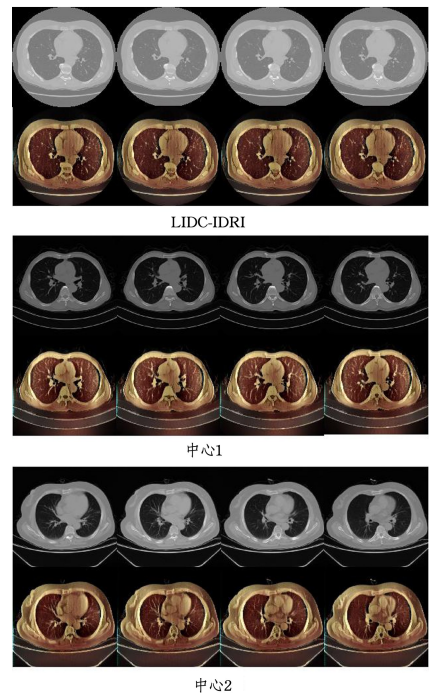


图 4 不同数据域上着色结果展示

Fig. 4 Display of coloring results on different data domains

4.5 消融实验


本文分别测试了不添加边缘和纹理约束模块(w/o edge+texture)、不添加纹理约束模块(w/o texture)、不添加边缘约束模块(w/o edge)以及使用本文方法这 4 种情况下的定性和定量实验结果。同时针对模型中 Block 的块数进行了消融实验,分别进行了 1 块、2 块、3 块 Blocks 下定性和定量的实验结果对比。

只有流模块的实验结果如图 5 中的第二行所示,很多 CT 图像的细小血管分支在着色后变得模糊,并且着色不均匀,在肺部的边缘位置没有着色成功。而没有纹理约束的情况下,实验结果如图 5 中的第三行所示。肺部整体偏暗,与真实图像的彩色差距较大,纹理特征不明显。图 5 中的第四行为没有边缘约束的情况,可以发现很多细小血管组织都已经丢失,与 CT 图像的组织结构有较大差距。本文方法如图 5 中的最后一行所示,可以很好地保留细小血管组织,着色后的颜色分布也比较均匀,纹理信息也进行了正确的迁移。表 2 列出了消融实验的定量对比,在 PSNR 上本文方法有较明显的提升,由 SSIM 的对比结果可以看出本文方法对于纹理结构的保持更有优势。在巴氏距离和直方图相关性上的定量对比上,本文方法均取得了很好的评分。

表 2 添加不同模块下消融实验的定量对比

Table 2 Quantitative comparison of ablation experiments with different modules

	w/o edge+ texture	w/o edge	w/o texture	本文方法
PSNR \uparrow	7.23	8.37	10.65	11.88
SSIM \uparrow	0.54	0.60	0.61	0.67
BD \downarrow	0.47	0.67	0.40	0.39
CORR \uparrow	0.76	0.80	0.70	0.91




(a) (b)

注:第一行是CT图像;第二行是不添加纹理约束和边缘约束下的实验结果;第三行是不添加纹理约束的实验结果;第四行是不添加边缘约束的实验结果;第五行是本文的实验结果。

图5 消融实验

Fig. 5 Ablation experiment

针对不同数量的 Block 对算法产生的影响,本文也做了相关的消融实验。如图6所示,本文分别在1块、2块和3块Block上做了实验。当只有一个Block时,图像着色不均匀,红色方框中没有生成肺部色彩,呈现为黑色。而当Block数量为3时,实验结果过拟合,红色方框中呈现为蓝色。同时,Block为1和3时,绿色方框中的组织边缘不明显,而当Block的数量为2时结果最佳。表3列出了不同Block下定量实验的对比结果,通过对比发现,当Block数量为2时达到最优。因此,本文选择Block的数量为2。



Block数量为1 Block数量为2 Block数量为3

图6 不同Block数量下的消融实验(电子版为彩图)

Fig. 6 Ablation experiments with different number of blocks

表3 不同Block数量的消融实验对比

Table 3 Comparison of ablation experiments with different number of blocks

	1	2	3
PSNR↑	11.53	11.88	11.80
SSIM↑	0.66	0.67	0.67
BD↓	0.30	0.39	0.31
CORR↑	0.88	0.91	0.86

结束语 本文提出了一种基于流模型的医学图像着色方法,可以实现从真实人体彩色图像到医学图像的颜色迁移

问题。虽然本文方法在肺部取得了较好的实验结果,但是在腹部等器官比较复杂部位还有一定的局限性。我们后续会采用用户交互的方式,实现腹部等复杂部位的医学图像着色任务。

参考文献

- [1] WELSH T, ASHIKHMIN M, MUELLER K. Transferring color to greyscale images[C]// Proceedings of the 29th Annual Conference on Computer Graphics and Interactive Techniques. 2002: 277-280.
- [2] KHAN T H, MOHAMMED S K, IMTIAZ M S, et al. Efficient color reproduction algorithm for endoscopic images based on dynamic color map[J]. Journal of Medical and Biological Engineering, 2016, 36: 226-235.
- [3] MATHUR A N, KHATTAR A, SHARMA O. 2D to 3D medical image colorization[C]// Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision. 2021: 2847-2856.
- [4] AN J, HUANG S, SONG Y, et al. Artflow: Unbiased image style transfer via reversible neural flows[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2021: 862-871.
- [5] GOODFELLOW I, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial networks[J]. Communications of the ACM, 2020, 63(11): 139-144.
- [6] DINH L, KRUEGER D, BENGIO Y. Nice: Non-linear independent components estimation[J]. arXiv:1410.8516, 2014.
- [7] DINH L, SOHL-DICKSTEIN J, BENGIO S. Density estimation using real nvp[J]. arXiv:1605.08803, 2016.
- [8] KINGMA D P, DHARIWAL P. Glow: Generative flow with invertible 1x1 convolutions[J]. Advances in Neural Information Processing Systems, 2018, 31: 10215-10224.
- [9] KLOKOV R, BOYER E, VERBEEK J. Discrete point flow networks for efficient point cloud generation[C]// European Conference on Computer Vision. Cham: Springer International Publishing, 2020: 694-710.
- [10] PUMAROLA A, POPOV S, MORENO-NOGUERF, et al. C-flow: Conditional generative flow models for images and 3d point clouds[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2020: 7949-7958.
- [11] LIU R, LIU Y, GONG X, et al. Conditional adversarial generative flow for controllable image synthesis[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2019: 7992-8001.
- [12] LIU R, LIU Y, GONG X, et al. Conditional adversarial generative flow for controllable image synthesis[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2019: 7992-8001.
- [13] ARDIZZONE L, LÜTH C, KRUSE J, et al. Guided image generation with conditional invertible neural networks[J]. arXiv: 1907.02392, 2019.
- [14] WINKLER C, WORRALL D, HOOGEBOOME, et al. Learning likelihoods with conditional normalizing flows[J]. arXiv:1912.

- 00042, 2019.
- [15] LUGMAYR A, DANELLJAN M, VAN GOOL L, et al. SrfLOW: Learning the super-resolution space with normalizing flow[C]// Computer Vision — ECCV 2020: 16th European Conference, Glasgow, UK, Part V 16. Springer International Publishing, 2020: 715-732.
- [16] GATYS L A, ECKER A S, BETHGE M. Image style transfer using convolutional neural networks[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2016: 2414-2423.
- [17] LUAN F, PARIS S, SHECHTMAN E, et al. Deep photo style transfer[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2017: 4990-4998.
- [18] ISOLA P, ZHU J Y, ZHOU T, et al. Image-to-image translation with conditional adversarial networks[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2017: 1125-1134.
- [19] ZHU J Y, PARK T, ISOLAP, et al. Unpaired image-to-image translation using cycle-consistent adversarial networks[C]// Proceedings of the IEEE International Conference on Computer Vision. 2017: 2223-2232.
- [20] DHARIWAL P, NICHOL A. Diffusion models beat gans on image synthesis[J]. Advances in Neural Information Processing Systems, 2021, 34: 8780-8794.
- [21] HO J, JAIN A, ABBEEL P. Denoising diffusion probabilistic models[J]. Advances in Neural Information Processing Systems, 2020, 33: 6840-6851.
- [22] KINGMA D P, WELLING M. Auto-encoding variational bayes[J]. arXiv:1312.6114, 2013.
- [23] IOFFE S, SZEGEDY C. Batch normalization: Accelerating deep network training by reducing internal covariate shift[C]// International Conference on Machine Learning. PMLR, 2015: 448-456.
- [24] LI Y, FANG C, YANG J, et al. Diversified texture synthesis with feed-forward networks[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2017: 3920-3928.
- [25] GATYS L, ECKER A S, BETHGE M. Texture synthesis using convolutional neural networks[J]. Advances in Neural Information Processing Systems, 2015, 28: 262-270.
- [26] ULYANOV D, LEBEDEV V, VEDALDI A, et al. Texture networks: Feed-forward synthesis of textures and stylized images[J]. arXiv:1603.03417, 2016.
- [27] ACKERMAN M J. The visible human project[J]. Proceedings of the IEEE, 1998, 86(3): 504-511.
- [28] ARMATO III S G, MCLENNAN G, BIDAUT L, et al. The lung image database consortium (LIDC) and image database resource initiative (IDRI): a completed reference database of lung nodules on CT scans[J]. Medical Physics, 2011, 38(2): 915-931.
- [29] WANG Z, BOVIK A C, SHEIKH H R, et al. Image quality assessment: from error visibility to structural similarity[J]. IEEE Transactions on Image Processing, 2004, 13(4): 600-612.
- [30] HUYNH-THU Q, GHANBARI M. Scope of validity of PSNR in image/video quality assessment[J]. Electronics Letters, 2008, 44(13): 800-801.
- [31] CHOI E, LEE C. Feature extraction based on the Bhattacharyya distance[J]. Pattern Recognition, 2003, 36(8): 1703-1709.
- [32] ROFER T. Using histogram correlation to create consistent laser scan maps[C]// IEEE/RSJ International Conference on Intelligent Robots and Systems. IEEE, 2002, 1: 625-630.
- [33] TORBUNOV D, HUANG Y, YU H, et al. Uvcgan: Unet vision transformer cycle-consistent gan for unpaired image-to-image translation[C]// Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision. 2023: 702-712.



WANG Xiaojie, born in 1990, doctoral student. Her main research interests include medical image processing and so on.



ZHOU Yuanfeng, born in 1980, Ph.D., professor. His main research interests include geometric modeling, information visualization, and image processing.

(责任编辑: 喻黎)