

基于半监督学习和生成对抗网络的医学图像融合算法

尹海涛*, 岳勇赢

南京邮电大学自动化学院、人工智能学院, 江苏 南京 210023

摘要 为了有效利用少量的医学图像标签数据和大量的无标签数据, 提出了一种基于半监督学习和生成对抗网络的医学图像融合算法。所提生成对抗网络融合架构包含 1 个生成器网络和 2 个判别器网络。采用半监督学习策略对所提网络进行训练, 主要包括监督训练、无监督训练、参数微调等 3 个阶段。此外, 生成器由面向融合任务的 U-Net 和 squeeze and excitation 通道注意力模块组成, 而判别器含有 3 层卷积层、1 层全连接层及 sigmoid 激活输出层。在各种不同模态医学图像上的实验结果表明, 与现有的 6 种基于深度学习的算法相比, 所提算法的主观视觉效果和客观性能指标都有一定竞争力。相关消融实验也验证了半监督学习策略能强化生成网络的性能, 提高融合图像的质量。

关键词 机器视觉; 生成对抗网络; 半监督学习; 医学图像融合; 注意力机制

中图分类号 TP391

文献标志码 A

DOI: 10.3788/LOP202259.2215005

Medical Image Fusion Based on Semisupervised Learning and Generative Adversarial Network

Yin Haitao*, Yue Yongying

College of Automation & College of Artificial Intelligence, Nanjing University of Posts and Telecommunications, Nanjing 210023, Jiangsu, China

Abstract To efficiently employ a small amount of labeled data, a medical image fusion network based on semisupervised learning and a generative adversarial network is developed. The developed fusion network comprises one generator and two discriminators. A semisupervised learning scheme is developed to train the network, including the supervised-training, unsupervised training, and parameters fine-tuning phases. Furthermore, the generator is constructed using a fusion inspired U-Net, squeeze and excitation attention modules. The discriminator contains three convolution layers, one fully connected layer, and a sigmoid activation function. The experimental findings on different multimodal medical images exhibit the proposed approach is competitive with six existing deep-learning based approaches in terms of visual effects and objective indexes. Moreover, the ablation investigations show the effectiveness of a semisupervised learning scheme that can enhance the quality of fused images.

Key words machine vision; generate adversarial network; semisupervised learning; medical image fusion; attention mechanism

1 引言

随着医学影像技术不断发展, 各种不同模态医学图像广泛应用于临床疾病诊断、辅助手术及健康监测等领域。常见的医学图像包括磁共振(MRI)图像、正电子发射断层(PET)图像、计算机断层扫描(CT)图像等。由于成像方式不同, 不同模态医学图像反应的身体结构信息也不同: MRI 图像显示软组织结构, 整体

解剖结构信息清晰; PET 图像可以提供丰富的人体代谢信息, 但是图像分辨率较低; CT 图像能够清晰显示骨骼信息, 但是无法提供软组织相关信息。在实际临床应用中, 病灶信息的全面描述有利于医生诊断。为了解决临床需求和成像技术局限之间的矛盾, 医学图像融合技术通过集成不同模态的医学图像信息生成一幅含有多模态互补信息的融合图像。图像融合技术以其方便、快捷、经济等特点, 得到了广泛关注。

收稿日期: 2021-08-12; 修回日期: 2021-08-30; 录用日期: 2021-10-13

基金项目: 国家自然科学基金(61971237)

通信作者: *haitaoyin@njupt.edu.cn

医学图像融合是图像融合的一种特殊形式。传统的图像融合方法主要包括空间域方法和变换域方法。典型的空域方法有逻辑滤波方法^[1]、颜色空间方法^[2]、基于主成分分析的融合方法^[3]等。变换域方法主要有稀疏表示方法^[4]、金字塔融合方法^[5]和小波变换融合方法^[6]等。传统融合方法的特征提取和融合规则大多需要人工设计,缺乏一定的普适性。

近些年,卷积神经网络以其强大的特征表示能力,在机器学习、计算机视觉和图像处理等领域取得巨大进步。文献[7]将卷积神经网络(CNN)应用于图像融合领域,并取得了一定的性能提升。为了解决基于多尺度分解的方法特征表达不准确、特征信息传输规则不准确等问题,文献[8]将CNN在shearlet变换域进行图像融合并取得了良好的融合效果。为了解决现有的医学图像融合方法忽略图像的语义,造成融合图像语义丢失的问题,文献[9]提出了一种基于语义的医学图像融合方法。此外,生成对抗网络(GAN)作为一种先进的无监督学习方法,也被应用于解决图像融合问题,比如FusionGAN^[10]及DDcGAN^[11]等。

现有基于深度学习方法的优越性能依赖于大量的含标签(参考图像)数据集。然而,针对医学图像融合任务的有标签图像很难获得。为了充分利用少量的有标签数据及大量的无监督数据,本文提出了一种基于半监督学习和GAN的医学图像融合框架。所提训练架构由监督训练阶段、无监督训练阶段和参数微调阶段组成,能够在保证训练稳定性的同时,提升网络的泛化能力。网络框架由U-Net结构和通道注意力机制混合构成,通道注意力使得网络能够更好地对有效特征通道进行筛分的同时,将特征提取层和重构层连接,以减少梯度消失的问题。在不同模态的医学图像融合实验结果表明,所提框架能够较好地完成医学图像各个模态有效信息的融合。

2 GAN和WGAN的相关知识

GAN由Goodfellow等^[12]提出,主要包括一个生成器 G 和一个判别器 D 。生成器主要用于生成符合预期的数据,并且将生成数据与真实数据的分布差距最小化。判别器用于判别输入数据是真实数据还是生成数据,并且将生成数据与真实数据的分布差距最大化。GAN的优化可以表示成下面的“min-max”优化问题:

$$\min_G \max_D V(G, D), \quad (1)$$

$$V(G, D) = E_{\mathbf{x} \sim P_{\text{real}}} [\log D(\mathbf{x})] + E_{\mathbf{z} \sim P_{\text{noise}}} \left\{ \log \left\{ 1 - D[G(\mathbf{z})] \right\} \right\}, \quad (2)$$

式中: E 表示数据分布期望; \mathbf{x} 为真实数据; \mathbf{z} 为输入的噪声数据。

传统GAN在训练过程中存在不稳定性,容易产生梯度消失、梯度爆炸和模型崩溃等问题。针对这些

问题,文献[13]提出了Wasserstein GAN(WGAN),WGAN采用Wasserstein距离,并将其转化为优化目标函数。WGAN生成器和判别器的优化目标可描述为

$$G = \arg \min_G E_{\mathbf{x} \sim P_{\text{g}}} [D_w(\mathbf{x})] - E_{\tilde{\mathbf{x}} \sim P_{\text{g}}} [D_w(\tilde{\mathbf{x}})], \quad (3)$$

$$D = \arg \max_D E_{\mathbf{x} \sim P_{\text{r}}} [D_w(\mathbf{x})] - E_{\tilde{\mathbf{x}} \sim P_{\text{g}}} [D_w(\tilde{\mathbf{x}})], \quad (4)$$

式中: P_{r} 表示真实数据分布; P_{g} 表示生成数据分布; $\tilde{\mathbf{x}} = G(\mathbf{x})$; w 表示截断参数。

WGAN-GP^[14]是WGAN的一种改进版本,在WGAN的判别器中增加了一个关于梯度惩罚的正则项,能提高网络训练的稳定性。WGAN-GP判别器的优化函数为

$$D = \arg \min_D E_{\tilde{\mathbf{x}} \sim P_{\text{g}}} [D(\tilde{\mathbf{x}})] - E_{\mathbf{x} \sim P_{\text{r}}} [D(\mathbf{x})] + \lambda E_{\tilde{\mathbf{x}} \sim P_{\text{g}}} \left\{ \left[\left\| \nabla_{\tilde{\mathbf{x}}} D(\tilde{\mathbf{x}}) \right\|_2 - 1 \right]^2 \right\}, \quad (5)$$

式中:从 \mathbf{x} 到 $\tilde{\mathbf{x}}$ 的随机采样数据 $\tilde{\mathbf{x}} = \epsilon \mathbf{x} + (1 - \epsilon) \tilde{\mathbf{x}}, 0 < \epsilon < 1$; $P_{\tilde{\mathbf{x}}}$ 表示采样数据分布; λ 为平衡参数。

3 所提算法

为了充分利用少量的含标签数据及大量的无标签数据,本实验组提出了一种基于半监督学习的医学图像融合网络模型。本小节将从整体框架、网络模型结构设计、损失函数设计等3个方面进行详细阐述。

3.1 算法整体框架

半监督学习(SSL)是一种将监督学习与无监督学习相结合的机器学习方法,广泛应用于模式识别、计算机视觉和图像处理等领域。半监督学习的核心思想是利用少量的含标签数据进行监督学习,利用大量的无标签进行无监督学习,能有效克服大量含标签数据获取难题,是当前深度学习领域的重要研究方向。在医学图像融合领域,含标签图像(融合参考图像)需要通过专业医学影像专家或者专业设备获取,获取难度大、数据量少。因此,提出了一种基于半监督学习和生成对抗网络的医学图像融合算法,简称为SSL-FWGAN。整体训练框架如图1所示。

所提SSL-FWGAN算法采用WGAN-GP思想,由一个生成器 G 和两个判别器 D_{m_1} 和 D_{m_2} 组成,并采用半监督学习对网络进行训练,主要包括下面3个训练阶段:

1) 监督训练阶段(对应图1中的phase 1)。采用少量的含参考标签的数据集对生成器进行监督学习,使得生成器获得较好的初始网络参数。在这个阶段,判别器不参与训练。

2) 无监督训练阶段(对应图1中的phase 2)。使用大量的无参考标签的数据集对生成器和判别器进行生成对抗训练。多模态源图像同时输入生成器,生成融合图像,根据损失函数计算生成融合图像与两个输入图像之间的分布差异,对生成器的参数进行优化。

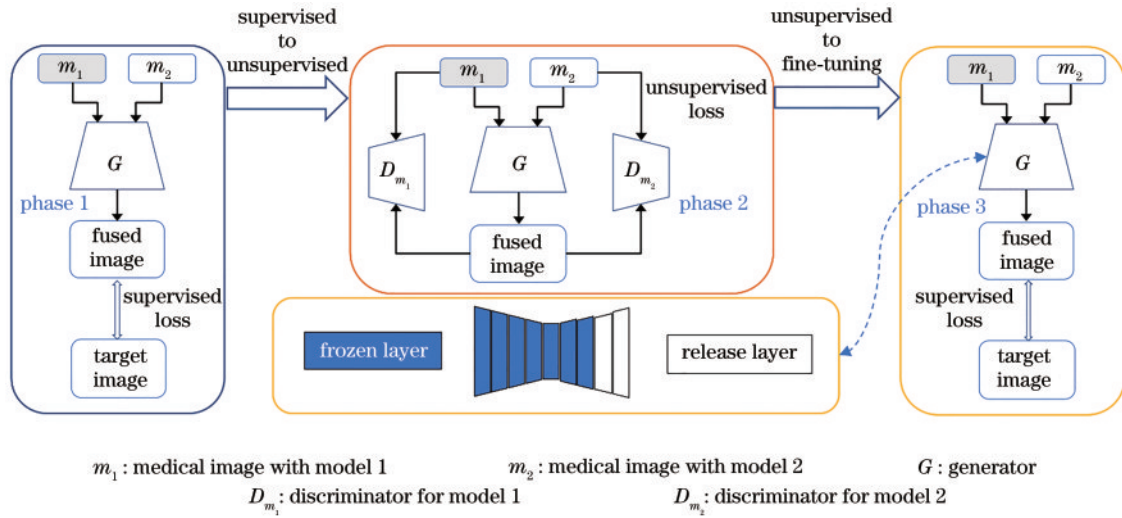


图 1 所提半监督训练示意图

Fig. 1 Schematic diagram of proposed semisupervised learning

同时,两个判别器分别对不同模态的源图像与生成的融合图像进行真伪判别,反馈给生成器,从而优化生成器。优化后的生成器会提升生成图像的质量,使得判别器进一步提高判别能力。重复上述过程,生成器和两个判别器相互对抗,不断提高生成器的泛化能力及生成图像的质量。

3) 参数微调阶段(对应图 1 中的 phase 3)。冻结网络其他层参数,利用监督训练策略仅对生成器最后

两层网络参数进行冻微调。

通过上述 3 个阶段依次进行训练,最终得到训练好的生成器和判别器。在测试阶段,只采用生成器生成融合图像。

3.2 生成器和判别器网络结构设计

所提 SSL-FWGAN 算法中含有一个生成器和两个判别器。生成器的网络结构如图 2 所示,分为编码部分和解码部分。

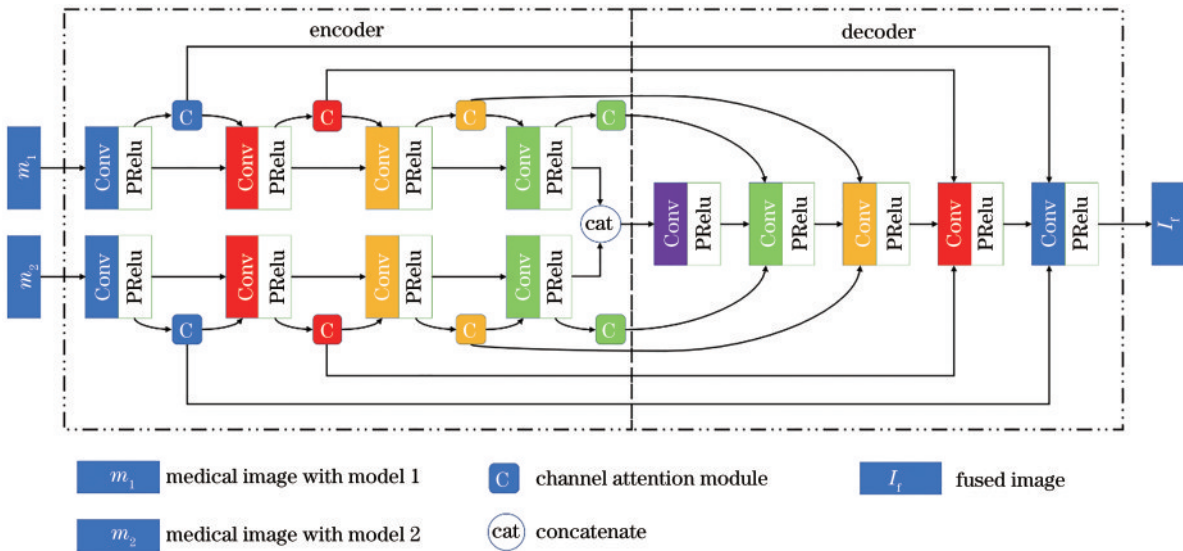


图 2 生成器网络结构图

Fig. 2 Architecture of generator network

类似于 U-Net^[15],所采用的生成器网络结构呈双 U 型。与 U-Net 不同之处在于,本实验组去掉了上/下采样模块,减少由于上/下采样产生的细节丢失。生成器的编码器由 4 层卷积层及层间的 squeeze and excitation(SE)注意力模块^[16]组成,其中 SE 注意力模块的网络结构图如图 3 所示。SE 注意力模块可以得到每个特征通道间的依赖关系,并给每个特征通道分

配权重,进一步加强含显著特征的通道重要性,从而提高网络对特征的选择性能。

此外,为了充分筛选有效特征通道,本实验组将编码器的特征通道输入通道注意力模块并与解码器相连。将网络中的浅层与深层网络联系起来,可以有效解决反向传播梯度过程中发生的梯度消失和网络退化问题。将经过通道注意力筛选过的显著特征与解码部




图 3 SE通道注意力模块

Fig. 3 SE channel attention module

分相连,能够大大提高解码部分对特征的选用能力,使其更加有效地重构图像。

对于判别器,采用双判别器分别判别融合图像与两种模态源图像之间的差异。两个判别器的结构相同,如图 4 所示,包括 3 层卷积层、1 个全连接层和一个 sigmoid 激活输出层。此外,卷积层采用 PReLU 激活函数。




图 4 判别器网络结构图

Fig. 4 Architecture of discriminator network

3.3 损失函数设计

所提半监督训练方法使用了多阶段训练的方式。针对不同训练阶段,采用的损失函数分为监督和无监督两种形式。

在监督训练阶段,使用像素损失和感知损失^[17],其表达式为

$$L_{\text{supervised}} = \alpha \frac{1}{N} \sum_{n=1}^N \|I_i - I_{\text{real}_n}\|_1 + (1 - \alpha) \|\psi(I_i) - \psi(I_{\text{real}})\|_2^2, \quad (6)$$

式中:第 1 项表示像素损失函数;第 2 项表示感知损失; α 是平衡参数; I_i 表示融合图像, I_{real} 表示参考图像; $\psi(\cdot)$ 表示采用 VGG16 网络进行提取特征^[18]。

无监督训练采用生成对抗的训练策略,对应下面的“min-max”优化问题:

$$\min_G \max_{D_{m_1}, D_{m_2}} E[D_{m_1}(I_{m_1})] - E\{D_{m_1}[G(I_{m_1}, I_{m_2})]\} + E[D_{m_2}(I_{m_2})] - E\{D_{m_2}[G(I_{m_1}, I_{m_2})]\}, \quad (7)$$

式中: I_{m_1} 和 I_{m_2} 表示不同模态的图像。

生成器不仅需要与判别器进行对抗训练,同时还需要保证生成图像与源图像间的内容相似性,因此引入了内容损失。为了有效度量不同模态图像的损失,生成器的损失函数包含了不同模态的对抗损失与内容损失:

$$L_G = \lambda_1(L_{m_1}^{\text{adv}} + \beta L_{m_1}^{\text{con}}) + \lambda_2(L_{m_2}^{\text{adv}} + \gamma L_{m_2}^{\text{con}}), \quad (8)$$

式中:第 1 项和第 2 项分别表示模态 m_1 和模态 m_2 的损失函数; $\lambda_1, \lambda_2, \beta, \gamma$ 为平衡参数。式(8)中 $L_{m_1}^{\text{adv}}$ 和 $L_{m_2}^{\text{adv}}$ 分别表示生成器 G 和判别器 D_{m_1} 与 D_{m_2} 间的对抗性损失:

$$\begin{cases} L_{m_1}^{\text{adv}} = E\{-D_{m_1}[G(I_{m_1}, I_{m_2})]\} \\ L_{m_2}^{\text{adv}} = E\{-D_{m_2}[G(I_{m_1}, I_{m_2})]\} \end{cases} \quad (9)$$

式(8)中 $L_{m_1}^{\text{con}}$ 和 $L_{m_2}^{\text{con}}$ 为根据不同模态图像采用的内容损失函数。针对 PET 图像,为了保持 PET 图像的代谢信息,采用均方误差作为损失函数:

$$L_{\text{PET}}^{\text{con}} = E\left[\|G(I_m, I_{\text{PET}}) - I_{\text{PET}}\|_F^2\right], \quad (10)$$

式中: I_{PET} 为 PET 图像; I_m 为另一模态图像。针对 MRI 图像或 CT 图像,为了保持源图像中纹理信息和轮廓,采用基于拉普拉斯特征的 1-范数约束作为损失函数:

$$L_{\text{MRI/CT}}^{\text{con}} = E\left[\| \text{Laplace}[G(I_{\text{MRI/CT}}, I_m)] - \text{Laplace}(I_{\text{MRI/CT}}) \|_1\right], \quad (11)$$

式中: $\text{Laplace}(\cdot)$ 表示拉普拉斯变换; $I_{\text{MRI/CT}}$ 表示 MRI 或者 CT 图像。

D_{m_1} 和 D_{m_2} 的对抗性损失采用 WGAN-GP 判别器的损失函数:

$$L_{D_i} = E\{D_i[G(I_{m_1}, I_{m_2})]\} - E\{D_i(I_i)\} + \lambda \left\{ \left[\|\nabla_{\hat{x}} D_i(\hat{x})\|_2 - 1 \right]^2 \right\}, i = m_1, m_2, \quad (12)$$

式中:从 $G(I_{m_1}, I_{m_2})$ 到 I_i 的随机采样数据 $\hat{x} = \epsilon G(I_{m_1}, I_{m_2}) + (1 - \epsilon)I_i, 0 < \epsilon < 1$ 。

4 实验结果分析

4.1 实验设置

实验所用数据集是从 <http://www.med.harvard.edu/AANLIB/home.html> 上下载得到的,选取 300 组 MRI(T1/T2)和 PET 图像进行无监督训练,50 组含标签数据用于监督训练。为了全面评估所提算法的性能,测试了 MRI-T1/PET、MRI-T2/PET、MRI-T1/MRI-T2、CT/MRI-T1 及 CT/MRI-T2 等 5 种类型的医学图像融合任务。

选取了 6 种基于深度学习的融合方法进行实验对比:1) 基于深度学习图像融合方法(Deepfuse)^[19]; 2) 基于生成对抗神经网络图像融合方法(FusionGAN)^[12]; 3) 基于对偶判别器生成对抗神经网络图像融合方法(DDcGAN)^[13]; 4) 基于深度图像分解的图像融合方法(DIDFuse)^[20]; 5) 用于多图像融合任务的统一无监督图像融合方法(U2Fusion)^[21]; 6) 基于

感知生成对抗网络的图像融合方法(PF-GAN)^[22]。为了保证实验的公平,对比实验全部使用论文作者所提供的最优模型。此外,采用互信息(MI)、空间频率(SF)、Yang 指标(Q_{yang})、平均梯度(AG)等4个性能评价指标进行客观评价。

所提算法采用 Pytorch 实现,运行环境如下: GTX 3080/10 GB RAM; Intel Core i7-10700K@3.80 GHz。在训练阶段, batch size 设置为 1, epoch 设置为 500。生成器和判别器均使用 Adabelif^[23] 优化器进行优化,初

始学习率设置为 0.0004。学习率衰减采用指数衰减,设置衰减参数为 0.98。

4.2 半监督训练和无监督训练对比

为了验证半监督训练方法的有效性,对其进行了消融实验。在其余训练条件和不变的情况下,仅对所提训练算法的第 2 阶段(无监督阶段)进行训练。以 MRI-T1/T2 和 CT 图像融合为例,测试结果如图 5 所示。表 1 为无监督训练和半监督训练的客观指标结果。




图 5 无监督训练和半监督训练的融合结果图。(a)MRI-T1 图像;(b)MRI-T2 图像;(c)(d)CT 图像;(e)(f)无监督训练生成的融合图像;(g)(h)半监督训练生成的融合图像

Fig. 5 Fused images of unsupervised learning and semisupervised learning. (a) MRI-T1 image; (b) MRI-T2 image; (c) (d) CT images; (e) (f) fused images of unsupervised training; (g) (h) fused images of semisupervised training

表 1 无监督训练和半监督训练的客观指标结果

Table 1 Index results of unsupervised training and semisupervised training

Training strategy	Fused result of MRI-T1 and CT images				Fused result of MRI-T2 and CT images			
	MI	SF	Q_{yang}	AG	MI	SF	Q_{yang}	AG
Unsupervised training	0.65	30.92	0.39	8.41	0.61	28.81	0.33	8.31
Semisupervised training	0.72	31.48	0.80	8.94	0.78	30.61	0.74	8.61

从图 5 中可以看出:无监督训练中生成的结果图[图 5(e)、(f)]的细节丢失严重,纹理不够清晰,整体图像较为模糊,这是 GAN 的生成多样性导致的;而半监督训练生成的结果图[图 5(g)、(h)]结构纹理信息清晰,对比度强,整体视觉效果优于无监督训练的结果。此外,表 1 的评价指标结果也表明,半监督训练方法优于无监督训练方法。

4.3 与其他融合算法的对比

本小节对 MRI-T1/PET、MRI-T2/PET、MRI-T1/MRI-T2、CT/MRI-T1 及 CT/MRI-T2 等 5 种不同类型医学图像融合进行实验对比分析。根据图像类型,进行了两组实验:1)灰度图像实验,“MRI-T1 与 MRI-T2 图像融合”“MRI-T1 与 CT 图像融合”“MRI-T2 与 CT 图像融合”;2)灰度与彩色图像实验,“MRI-

T1 与 PET 图像融合”“MRI-T2 与 PET 图像融合”。

4.3.1 灰度图像实验

每类灰度图像融合任务的测试集含有 2 组 256×256 的图像,分别取其中一组融合结果进行展示。图 6、图 7 和图 8 分别为 MRI-T1 和 MRI-T2 融合结果、MRI-T1 和 CT 图像融合结果及 MRI-T2 和 CT 图像融合结果。从[图 6(g)、图 7(g)、图 8(g)]可以看出, FusionGAN 的融合图像质量较差,信息丢失严重;从[图 6(e)、图 7(e)、图 8(e)]可以看出, Deepfuse 的整体图像质量和保留信息较好,但是对比度和亮度过低;从[图 6(d)、图 7(d)、图 8(d)和图 6(h)、图 7(h)、图 8(h)]可以看出, DDcGAN 和 PF-GAN 的融合图像亮度和对比度较高,但亮度过高也导致了图像高频细节丢失,不利于人眼观察;从[图 6(f)、图 7(f)、图 8(f)]可以看出,




图 6 MRI-T1 图像与 MRI-T2 图像的融合结果。(a) MRI-T1; (b) MRI-T2; (c) U2Fusion; (d) DDcGAN; (e) Deepfuse; (f) DIDFuse; (g) FusionGAN; (h) PF-GAN; (i) SSL-FWGAN

Fig. 6 Fused results of MRI-T1 and MRI-T2 images. (a) MRI-T1; (b) MRI-T2; (c) U2Fusion; (d) DDcGAN; (e) Deepfuse; (f) DIDFuse; (g) FusionGAN; (h) PF-GAN; (i) SSL-FWGAN




图 7 MRI-T1 图像与 CT 图像的融合结果。(a) MRI-T1; (b) CT; (c) U2Fusion; (d) DDcGAN; (e) Deepfuse; (f) DIDFuse; (g) FusionGAN; (h) PF-GAN; (i) SSL-FWGAN

Fig. 7 Fused results of MRI-T1 and CT images. (a) MRI-T1; (b) CT; (c) U2Fusion; (d) DDcGAN; (e) Deepfuse; (f) DIDFuse; (g) FusionGAN; (h) PF-GAN; (i) SSL-FWGAN

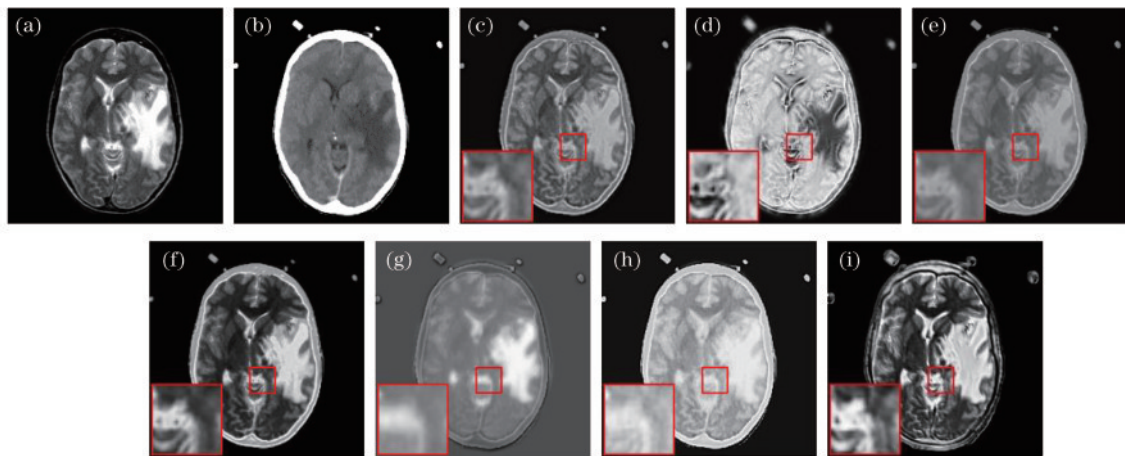


图 8 MRI-T2 图像与 CT 图像的融合结果。(a) MRI-T2; (b) CT; (c) U2Fusion; (d) DDcGAN; (e) Deepfuse; (f) DIDFuse; (g) FusionGAN; (h) PF-GAN; (i) SSL-FWGAN

Fig. 8 Fused results of MRI-T2 and CT images. (a) MRI-T1; (b) CT; (c) U2Fusion; (d) DDcGAN; (e) Deepfuse; (f) DIDFuse; (g) FusionGAN; (h) PF-GAN; (i) SSL-FWGAN

DIDFuse 的融合图像虽然细节纹理特征清晰,但骨骼边缘信息丢失严重;从[图 6(c)、图 7(c)、图 8(c)]可以看出,U2Fusion 的融合图像纹理清晰,对源图像信息保留较好,但是对比度不够。相比之下,所提算法生成的融合图像[图 6(i)、图 7(i)、图 8(i)]的软组织和骨骼信息更清晰,病灶部位细节对比度高,细节丰富,很好地保留了源图像中的信息。

表 2 给出了每类融合任务的在客观指标。从表 2

可以看出:所提算法针对该三类医学图像融合任务在 SF、 Q_{yang} 和 AG 指标上均取得了最好的效果;对于 MI 指标中,所提算法仅次于 Deepfuse。客观指标与视觉效果表明,所提算法在融合 MRI 图像和 CT 图像、融合不同模态的 MRI 图像上优于其他 6 种基于深度学习的融合算法。综合主客观评价与现有基于深度学习的融合方法对比,所提算法在融合 MRI 和 CT 图像时具有一定的竞争力。

表 2 不同方法针对灰度图像融合的客观指标结果

Table 2 Index results of different methods for fusing gray images

Method	MRI-T1 and MRI-T2 images				MRI-T1 and CT images				MRI-T2 and CT images			
	MI	SF	Q_{yang}	AG	MI	SF	Q_{yang}	AG	MI	SF	Q_{yang}	AG
Deepfuse	0.88	20.58	0.38	5.28	0.93	19.29	0.34	2.84	0.97	16.94	0.35	4.06
FusionGAN	0.60	14.62	0.29	4.44	0.61	11.96	0.23	4.46	0.67	10.27	0.21	2.54
PF-GAN	0.68	33.58	0.35	7.76	0.67	26.53	0.37	6.06	0.69	29.19	0.32	5.75
DDcGAN	0.61	33.51	0.35	7.92	0.60	30.94	0.37	3.65	0.54	30.84	0.26	8.74
DIDFuse	0.75	28.14	0.45	6.71	0.74	25.65	0.36	4.34	0.71	24.72	0.36	6.35
U2Fusion	0.71	24.83	0.34	6.75	0.68	22.52	0.37	6.04	0.69	20.73	0.37	5.79
SSL-FWGAN	0.76	33.74	0.76	9.32	0.74	32.41	0.79	8.69	0.74	32.34	0.75	9.48

4.3.2 灰度与彩色图像实验

针对 MRI 和 PET 图像融合任务:首先将 PET 图像进行 YCbCr 颜色空间转换;然后采用所提算法对 Y

分量与 MRI 图像进行融合;最后通过 YCbCr 进行逆变换得到最终的融合图像。整个融合的过程如图 9 所示。




图 9 针对 MRI 与 PET 图像 SSL-FWGAN 的实施流程

Fig. 9 Implementation of SSL-FWGAN for fusing MRI and PET images

本实验组进行了 MRI-T1 和 PET 图像融合及 MRI-T2 和 PET 图像融合,每类融合任务的测试集包括 40 组 256×256 源图像。图 10 和图 11 分别显示了每类融合任务的一组实验结果。从[图 10(d)、图 11(d)和图 10(h)、图 11(h)]可以看出,DDcGAN 和 PF-GAN 的融合图像由于亮度过高导致代谢信息清晰度不够;从[图 10(e)、图 11(e)]可以看出,Deepfuse 的融合图像结构虽然清晰,但是亮度和对比度较低;从[图 10(f)、图 11(f)和图 10(c)、图 11(c)]可以看出,DIDFuse 和 U2Fusion 融合图像的边缘骨骼信息存在丢失的情况,且 DIDFuse 结果过暗,不利于诊断观察;

从[图 10(g)、图 11(g)]可以看出,FusionGAN 融合结果模糊,且颜色信息出现偏差;所提算法针对 MRI-T1 与 PET 图像的融合结果[图 10(i)]信息保留完好、对比度较高、纹理清晰;但在对 MRI-T2 和 PET 图像进行融合时,出现了色彩偏差,如[图 11(i)]所示。这是由于在测试集中 MRI-T2 图像的质量不高、软组织部分不清晰,网络在提取特征时不能有效地提取到显著特征,在重构图像时赋予图像信息不完全,最终融合图像颜色信息时出现偏差。

表 3 为不同算法针对彩色图像融合的客观指标结果。由表 3 的评价指标可知,所提算法在图像质量较




图 10 MRI-T1 图像与 PET 图像的融合结果。(a) MRI-T1; (b) PET; (c) U2Fusion; (d) DDcGAN; (e) Deepfuse; (f) DIDFuse; (g) FusionGAN; (h) PF-GAN; (i) SSL-FWGAN

Fig. 10 Fused results of MRI-T1 and PET images. (a) MRI-T1; (b) PET; (c) U2Fusion; (d) DDcGAN; (e) Deepfuse; (f) DIDFuse; (g) FusionGAN; (h) PF-GAN; (i) SSL-FWGAN




图 11 MRI-T2 图像与 PET 图像的融合结果。(a) MRI-T2; (b) PET; (c) U2Fusion; (d) DDcGAN; (e) Deepfuse; (f) DIDFuse; (g) FusionGAN; (h) PF-GAN; (i) SSL-FWGAN

Fig. 11 Fused results of MRI-T2 and PET images. (a) MRI-T1; (b) PET; (c) U2Fusion; (d) DDcGAN; (e) Deepfuse; (f) DIDFuse; (g) FusionGAN; (h) PF-GAN; (i) SSL-FWGAN

表 3 不同方法针对彩色图像融合的客观指标结果

Table 3 Index results of different methods for fusing color images

Method	MRI-T1 and PET images				MRI-T2 and PET images			
	MI	SF	Q_{yang}	AG	MI	SF	Q_{yang}	AG
Deepfuse	0.91	23.71	0.49	7.81	0.91	13.09	0.47	4.37
FusionGAN	0.43	14.09	0.29	4.94	0.49	10.68	0.29	3.40
PF-GAN	0.54	34.26	0.51	10.66	0.60	18.59	0.42	6.28
DDcGAN	0.47	43.59	0.54	13.50	0.52	26.49	0.34	8.33
DIDFuse	0.47	23.44	0.26	7.52	0.67	16.00	0.40	5.05
U2Fusion	0.55	26.85	0.34	9.13	0.64	15.24	0.27	4.40
SSL-FWGAN	0.56	47.28	0.57	15.56	0.49	27.09	0.44	9.21

好的 MRI-T1 与 PET 图像融合结果上, SF、 Q_{yang} 和 AG 都取得了最好的效果, 并且取得第 2 好的 MI 指标结果。对于 MRI-T2 与 PET 图像的融合, 所提算法在 SF 和 AG 指标上取得最好结果。Deepfuse 的 MI 指标优于其他方法, 这是由于实验采用的 Deepfuse 模型是由作者提供的预训练模型, 其通过 COCO 数据集进行监督学习得到, 能有效地保留源图像的信息。但是融合图像的视觉效果仍不能满足医学图像对亮度和对比度的要求, 所以 Deepfuse 在其他 3 个指标中对比其他算法仍有差距。整体上讲, 与现有基于深度学习的融合算法相比, 所提算法在融合 MRI 和 PET 图像时具有一定的竞争力。

5 结 论

设计了一种基于半监督训练的生成对抗网络融合框架: 在训练阶段, 采用分阶段训练来完成半监督训练的任务; 在网络中插入通道注意力机制, 使得网络可以自主学习到有效的通道特征, 减少无效特征的权重; 在损失函数中, 针对不同模态的数据设计了不同的内容损失函数, 以驱动网络高效学习到不同模态的特征。实验结果表明, 所设计半监督训练方式可以提高训练效果及训练的稳定性, 且在主观视觉效果和客观评价中都取得了良好的效果。

现有融合网络主要面向高质量的源图像, 对质量较差的图像融合效果欠佳, 因此接下来的工作主要面向低质量图像融合问题, 进一步改进所提融合网络, 提升网络性能。

参 考 文 献

- [1] Liu J G. Smoothing filter-based intensity modulation: a spectral preserve image fusion technique for improving spatial details[J]. *International Journal of Remote Sensing*, 2000, 21(18): 3461-3472.
- [2] Daneshvar S, Ghassemian H. MRI and PET image fusion by combining IHS and retina-inspired models[J]. *Information Fusion*, 2010, 11(2): 114-123.
- [3] 苏金凤, 张贵仓, 汪凯. 结合鲁棒主成分分析和非下采样轮廓波变换的红外与可见光图像的压缩融合[J]. *激光与光电子学进展*, 2020, 57(4): 041005.
Su J F, Zhang G C, Wang K. Compressed fusion of infrared and visible images combining robust principal component analysis and non-subsampled contour transform[J]. *Laser & Optoelectronics Progress*, 2020, 57(4): 041005.
- [4] 王加新, 陈升, 谢明鸿. 基于低秩分解和卷积稀疏编码的多源图像融合[J]. *激光与光电子学进展*, 2021, 58(22): 2210009.
Wang J X, Chen S, Xie M H. Multi-source image fusion based on low-rank decomposition and convolutional sparse coding[J]. *Laser & Optoelectronics Progress*, 2021, 58(22): 2210009.
- [5] Wang Z B, Cui Z J, Zhu Y. Multi-modal medical image

- fusion by Laplacian pyramid and adaptive sparse representation[J]. *Computers in Biology and Medicine*, 2020, 123: 103823.
- [6] 赵贺, 张金秀, 张正刚. 基于 NSCT 与 DWT 的 PCNN 医学图像融合[J]. *激光与光电子学进展*, 2021, 58(20): 2017002.
Zhao H, Zhang J X, Zhang Z G. PCNN medical image fusion based on NSCT and DWT[J]. *Laser & Optoelectronics Progress*, 2021, 58(20): 2017002.
- [7] Liu Y, Chen X, Peng H, et al. Multi-focus image fusion with a deep convolutional neural network[J]. *Information Fusion*, 2017, 36: 191-207.
- [8] Liu Y, Chen X, Cheng J, et al. A medical image fusion method based on convolutional neural networks[C]//2017 20th International Conference on Information Fusion (Fusion), July 10-13, 2017, Xi'an, China. New York: IEEE Press, 2017.
- [9] Fan F D, Huang Y Y, Wang L, et al. A semantic-based medical image fusion approach[EB/OL]. (2019-06-01) [2021-02-05]. <https://arxiv.org/abs/1906.00225>.
- [10] Ma J Y, Yu W, Liang P W, et al. FusionGAN: a generative adversarial network for infrared and visible image fusion[J]. *Information Fusion*, 2019, 48: 11-26.
- [11] Ma J Y, Xu H, Jiang J J, et al. DDcGAN: a dual-discriminator conditional generative adversarial network for multi-resolution image fusion[J]. *IEEE Transactions on Image Processing*, 2020, 29: 4980-4995.
- [12] Goodfellow I J, Pouget-Abadie J, Mirza M, et al. Generative adversarial nets[C]//Advances in Neural Information Processing Systems 2014, December 8-13, 2014, Montreal, Quebec, Canada. [S.l.: s.n.], 2014: 2672-2680.
- [13] Arjovsky M, Chintala S, Bottou L. Wasserstein generative adversarial networks[C]//Proceedings of 2017 International Conference on Machine Learning, August 6-11, 2017, Sydney, Australia. Pennsylvania: IMLS, 2017: 214-223.
- [14] Gulrajani I, Ahmed F, Arjovsky M, et al. Improved training of Wasserstein GANs[C]//Advances in Neural Information Processing Systems (NIPS), December 4-9, 2017, Long Beach, California, USA. [S.l.: s.n.], 2017: 2226-2234.
- [15] Ronneberger O, Fischer P, Brox T. U-net: convolutional networks for biomedical image segmentation[M]//Navab N, Hornegger J, Wells W M, et al. Medical image computing and computer-assisted intervention-MICCAI 2015. Lecture notes in computer science. Cham: Springer, 2015, 9351: 234-241.
- [16] Hu J, Shen L, Sun G. Squeeze-and-excitation networks [C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 7132-7141.
- [17] Johnson J, Alahi A, Li F F. Perceptual losses for real-time style transfer and super-resolution[M]//Leibe B, Matas J, Sebe N, et al. Computer vision-ECCV 2016. Lecture notes in computer science. Cham: Springer,

- 2016, 9906: 694-711.
- [18] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition[EB/OL]. (2014-09-04)[2021-04-05]. <https://arxiv.org/abs/1409.1556>.
- [19] Prabhakar K R, Srikar V S, Babu R V. DeepFuse: a deep unsupervised approach for exposure fusion with extreme exposure image pairs[C]//2017 IEEE International Conference on Computer Vision, October 22-29, 2017, Venice, Italy. New York: IEEE Press, 2017: 4724-4732.
- [20] Zhao Z X, Xu S, Zhang C X, et al. DIDFuse: deep image decomposition for infrared and visible image fusion [EB/OL]. (2020-03-20)[2021-04-05]. <https://arxiv.org/abs/2003.09210>.
- [21] Xu H, Ma J Y, Jiang J J, et al. U2Fusion: a unified unsupervised image fusion network[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2022, 44 (1): 502-518.
- [22] Fu Y, Wu X J, Durrani T. Image fusion based on generative adversarial network consistent with perception [J]. Information Fusion, 2021, 72: 110-125.
- [23] Zhuang J T, Tang T, Ding Y F, et al. AdaBelief optimizer: adapting stepsizes by the belief in observed gradients[EB/OL]. (2020-10-15) [2021-04-02]. <https://arxiv.org/abs/2010.07468>.