

基于生成对抗网络的肺结节数据增扩技术研究

周俊豪, 姬正杰, 任涵煜, 王安童, 向 玺, 陈 萌*

宁波工程学院网络空间安全学院, 浙江 宁波

收稿日期: 2024年5月22日; 录用日期: 2024年6月21日; 发布日期: 2024年6月28日

摘 要

针对医疗影像中特定种类数据不足的问题, 主要探索了基于生成对抗网络(GAN)的肺结节数据增扩技术。采用了改进的生成对抗网络技术对原始肺结节影像数据集进行数据增扩。并在LIDC-IDRI数据集上进行了验证。实验结果表明, 与DCGAN相比, 基于WGAN-GP网络结构的GAN技术在生成肺结节影像方面FID指标均值达到137.85, 表现更佳。此外, 经过其他三种生成图像质量评估指标综合测试, WGAN-GP网络生成的肺结节数据更接近真实数据分布, 生成图像质量较高。

关键词

生成对抗网络(GAN), 医疗影像, 数据增扩

Research on Lung Nodules Data Augmentation Technology Based on Generative Adversarial Networks

Junhao Zhou, Zhengjie Ji, Hanyu Ren, Antong Wang, Xi Xiang, Meng Chen*

School of Cyber Science and Engineering, Ningbo University of Technology, Ningbo Zhejiang

Received: May 22nd, 2024; accepted: Jun. 21st, 2024; published: Jun. 28th, 2024

Abstract

In response to the issue of insufficient data of specific types in medical imaging, this study primarily explores lung nodules data augmentation techniques based on Generative Adversarial Networks (GAN). An enhanced generative adversarial network technique was employed to augment the original lung nodule image dataset, which was subsequently validated using the LIDC-IDRI da-

*通讯作者。

文章引用: 周俊豪, 姬正杰, 任涵煜, 王安童, 向玺, 陈萌. 基于生成对抗网络的肺结节数据增扩技术研究[J]. 计算机科学与应用, 2024, 14(6): 131-136. DOI: 10.12677/csa.2024.146149

taset. Experimental findings demonstrate that, compared to DCGAN, GAN technology utilizing the WGAN-GP network architecture excels in generating lung nodules images, yielding an average FID index of 137.85. Furthermore, following comprehensive evaluation of three additional image quality assessment metrics, it was found that lung nodules data generated by the WGAN-GP network closely approximates the distribution of real data, resulting in higher image quality.

Keywords

Generative Adversarial Networks (GAN), Medical Images, Data Augmentation

Copyright © 2024 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

随着人工智能和深度学习的不断发展,越来越多的学者对医疗影像生成任务产生了浓厚兴趣。影像科医生长期从事高负荷的工作,不可避免地会产生视觉疲劳,出现漏、误诊等问题,基于人工智能的智能诊断系统可减轻放射科和临床医生的报告撰写负荷和诊断压力[1],人工智能与医疗影像技术的融合应用,可大大提高疾病诊断的效率与质量。但训练具有高准确性的模型一般需要大量的数据,某些病例的每年发生总数少,并且医疗数据具有强隐私性,在个别医院掌握病例少的情况下,医院用自己的少量数据训练属于自己的高准确性模型较困难。而随着近年生成式模型的发展,有望解决这一问题,其中生成对抗网络技术(GAN)由于独特的对抗性思想被广泛应用[2]。生成对抗网络是 GOODFELLOW 等[3]受零和博弈启发,提出了一种由生成器(G)和判别器(D)组成的对抗网络,生成对抗网络为解决医疗影像集不足的情况提供了新的思路。本文提出一种使用生成对抗网络的方法对肺结节影像数据集进行数据增扩,并采用改进网络结构的生成对抗技术对肺结节数据进行生成实验。

2. 研究背景

2.1. 图像增扩技术

由于医学成像技术的限制、标注过程耗时昂贵,以及隐私安全问题,使得医疗数据集增扩成为相关研究领域的热点问题。传统的数据集增扩方式主要包括样本采样和仿射变换两种方法。样本采样技术主要是改变数据集的原始分布,包括降采样、过采样或二者结合,以扩大数据集的图像总量。另一种传统方法是仿射变换,它是一种二维坐标到二维坐标之间的线性变换。通过仿射变换,可以实现图像的旋转、镜像、拉伸等操作,从而增加图像数据集的总量。除了样本采样和仿射变换外,还有一些其他方法,如扣取、遮罩、缩放、加噪等处理方式,其原理与仿射变换相同,通过改变原图的表现形式来改变其特征矩阵,从而迫使网络从语义上去理解图片,达到对数据集的增扩目的。

目前,国内外已经在图像补全、图像修复、图像翻译、图像上色、视频生成等应用领域开展生成对抗网络算法研究的工作[4],特别是图像修复领域已经取得了不少研究成果[5] [6] [7] [8] [9]。近年来,GAN技术在医疗领域也取得了不少研究成果。例如,文献[10] [11] [12]利用生成对抗网络技术,将含有噪声的医疗图像重建为清晰图像,为医护人员做出更准确的诊断提供了更好的基础。文献[13] [14] [15]利用生成对抗网络技术,对医疗影像重建进行了有效的研究探索。但使用生成对抗网络进行医疗图像增扩的研究相对比较缺乏,因此使用生成对抗网络技术对肺结节影像增扩具有较好的研究意义。

2.2. 生成对抗网络技术

2.2.1. GAN

生成对抗网络(GAN)主要原理是通过对输入随机噪声的处理,生成器不断生成虚假的数据,判别器的任务则是判别生成器所生成数据的真假,二者在相互对抗的过程中互相学习逐渐变强。最终,通过这种博弈,生成器可输出与真实数据相似度极高的新数据。生成对抗网络基本结构如图 1 所示。

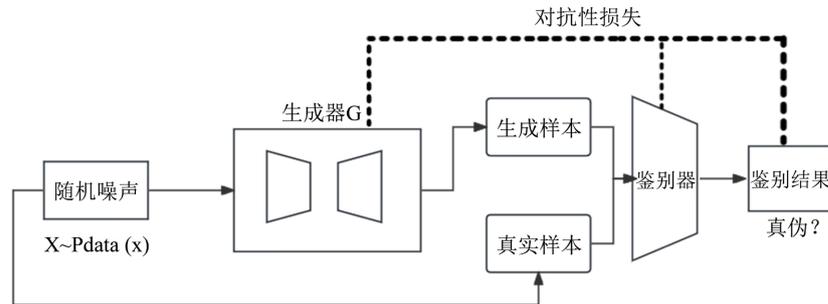


Figure 1. Basic structure of GAN network

图 1. GAN 网络基本结构图

2.2.2. DCGAN

由 RADFORD 等[16]提出的 DCGAN (Deep Convolutional Generative Adversarial Network), 是一种改进的生成对抗网络模型架构。它开创性的将 CNN 与 GAN 网络相结合, 显著提高了性能。相比于普通的 GAN, DCGAN 在学习医疗影像数据病灶特征方面更具适应性和丰富性。它能够捕获医疗影像隐含的特征分布, 并合成全新的数据样本。

本文使用的 DCGAN 网络的生成网络结构如图 2 所示, 其可提高 GAN 生成图片的稳定性、以及生成质量和种类丰富度。虽然改进的 DCGAN 性能上有所提升, 但是并未解决 GAN 训练过程中的稳定性问题, 在训练时仍需平衡生成器与鉴别器的训练进程[17]。

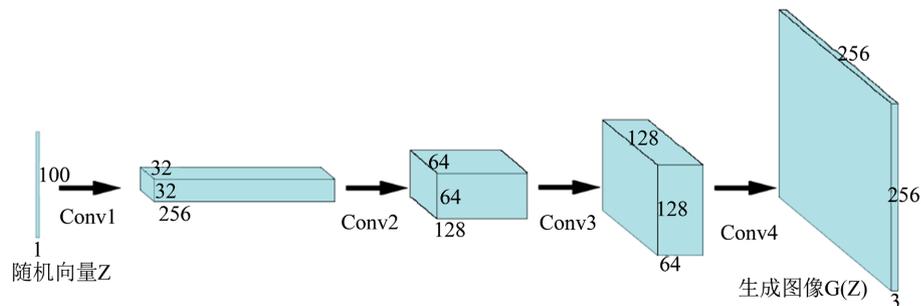


Figure 2. Architecture of the DCGAN generator network

图 2. DCGAN 生成网络结构图

2.2.3. WGAN-GP

由于原始 GAN 网络存在会导致梯度不稳定的问题, WGAN (Wasserstein Generative Adversarial Network) [18]改进了原始 GAN 网络的损失函数, 并采用沃瑟斯坦(Wassertein)距离来优化 GAN 结构的损失函数, 从根本上解决了原始 GAN 网络训练过程中梯度消失的问题。但由于 WGAN 网络使用的 Wasserstein 距离需要满足 Lipschitz 连续性限制条件, 采用了权重裁剪的方式, 这会导致模型建模能力弱化, 容易出现梯度消失以及梯度爆炸问题。改进 WGAN-GP [19]通过梯度惩罚的方式改善了 WGAN 网

络的训练稳定性,避免了梯度消失和爆炸问题,并提高了模型的建模能力,使得生成器可以更好地学习真实数据分布的特征。

3. 实验结果

3.1. 生成实验

本文使用数据集为 LIDC-IDRI (The Lung Image Database Consortium) 公开数据集[20],选取了其中 300 例 Dicom 格式的病例,并经过预处理后得到 3050 张 256×256 格式大小的肺结节影像数据,其中 2729 张作为训练数据集,321 张作为测试数据集,LIDC 数据集中原始肺结节图像如图 3 所示。训练前统一设置每次训练输入肺结节数据数量(Batchsize)为 16 张,训练轮数(Epoch)为 500 轮,随后将肺结节影像数据分别输入 DCGAN 和 WGAN-GP 网络进行训练。训练完成后,综合评估生成器损失(G_Loss)与鉴别器损失(D_Loss),保存最佳生成器网络的模型文件。DCGAN 网络与 WGAN-GP 网络生成肺结节数据图像分别如图 4、图 5 所示。

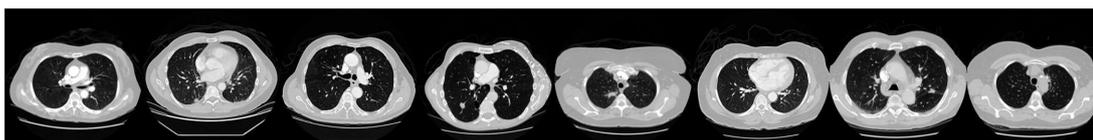


Figure 3. Original lung nodules images from the LIDC dataset

图 3. LIDC 数据集原始肺结节图像

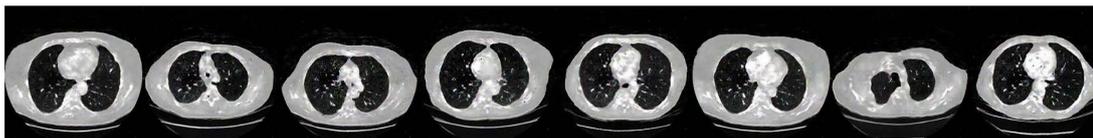


Figure 4. Lung nodules images generated by the DCGAN network

图 4. DCGAN 网络生成肺结节图像结果

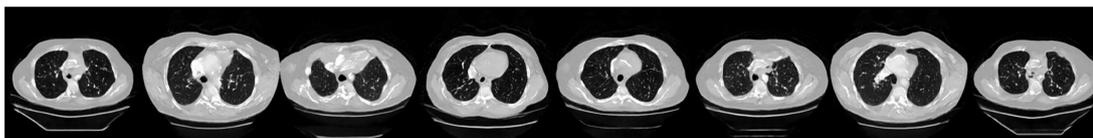


Figure 5. Lung nodules images generated by the WGAN-GP network

图 5. WGAN-GP 网络生成肺结节图像结果

3.2. 实验评估方式

3.2.1. IS 指标

IS (Inception Score) 指标使用图像分类网络 Inception V3 Network 来评估 GAN 网络中生成器生成的图片的质量。主要是将模型生成的图片输入到预训练的网络 Inception V3 Network 中,根据分类网络输出的概率分布来评估生成图像的质量。IS 但由于输出的 IS 指标过分依赖于 Inception V3 Network,而 Inception V3 Network 是根据 ImageNet 数据集训练的,如果评价的数据集与训练分类网络的数据集相差过大时,可能不足以全面评估生成图片的质量,所以我们采用多种指标方式综合评估 GAN 网络中生成器的质量。计算 IS 指标的公式如下所示:

$$IS(G) = \exp\left(\mathbb{E}_{x \sim p_g} D_{KL}(p(y|x) \| p(y))\right) \quad (1)$$

3.2.2. FID 指标

与 IS 指标性相比, FID (Fréchet Inception Distance) [21] 指标通过比较真实图像分布和生成图像分布之间的距离来综合评估生成图像的质量。同样是根据分类网络 Inception V3 Network 计算, 但测试 FID 指标时将会同时输入真实图像和生成图像到分类网络中, 再从中提取并计算真实图像的分布以及生成对抗网络生成图像分布之间的距离, 其中距离越小代表着生成器生成的图像越接近于真实图像的分布, 代表着生成的图像质量越高, 因此 FID 越小越好。我们使用式(2)计算图像数据的 FID 值。

$$\text{FID}(x, g) = \|\mu_x - \mu_g\| + \text{Tr} \left(\sum_x + \sum_g - 2 \left(\sum_x \sum_g \right)^{\frac{1}{2}} \right) \quad (2)$$

3.3. 实验评估结果

使用训练好的生成器模型输出生成的肺结节数据图像, 为了保证结果的公平性, DCGAN 网络与 WGAN-GP 网络生成的肺结节影像数量都为 321 张, 与测试的真实图像数据集保持一致。我们首先使用 IS 与 FID 指标对生成的图像进行评估, 结果如表 1 所示。接下来, 使用 SSIM (Structural Similarity Index) 和 PSNR (Peak Signal-to-Noise Ratio) 指标来评估生成图像的质量以及与原始图像相似性。结果如表 2 所示。

Table 1. Comparison of IS and FID Values for lung nodules images generated by different models

表 1. 不同模型的生成的肺结节图像的 IS 和 FID 均值对比

| 模型 | MIS | MFID |
|---------|------|--------|
| DCGAN | 1.57 | 144.41 |
| WGAN-GP | 1.74 | 137.85 |

Table 2. Comparison of mean SSIM and PSNR values for lung nodules images generated by different models compared to real images

表 2. 不同模型生成肺结节图像与真实图像的 SSIM 和 PSNR 均值对比

| 模型 | MSSIM | MPSNR |
|---------|-------|-------|
| DCGAN | 0.40 | 30.03 |
| WGAN-GP | 0.44 | 30.24 |

3.4. 实验结果分析

从表 1 可以得出, WGAN-GP 网络在生成肺结节图像的四个评估指标中均表现优于 DCGAN 网络。从 IS 和 FID 指标的角度来看, WGAN-GP 网络相较于 DCGAN 网络表现更优。WGAN-GP 网络的 IS 均值为 1.74, 高于 DCGAN 网络的 1.57。而 FID 均值为 137.85, 低于 DCGAN 网络的 144.41。这表明 WGAN-GP 网络生成的图像在质量和多样性方面均优于 DCGAN 网络, 且更接近于真实图像的分布。从而表明其生成的图像质量更高。

SSIM 评估了生成的图像与真实图像之间的结构相似性, 而 PSNR 评估了信号与噪声之间的比例。从 SSIM 和 PSNR 指标来看, WGAN-GP 网络在 SSIM 和 PSNR 上也表现更好。WGAN-GP 网络的 MSSIM 为 0.44, 高于 DCGAN 网络的 0.40, 而 MPSNR 为 30.24, 略高于 DCGAN 网络的 30.03。这表明 WGAN-GP 网络生成的图像在结构相似性和信噪比方面都更接近于真实图像, 具有更高的质量和清晰度, 其中包含更多的细节和复杂性。

综合来看, WGAN-GP 网络相较于 DCGAN 网络在生成肺结节影像方面表现出更好的性能。其引入的梯度惩罚机制有效提高了模型的训练稳定性, 从而生成了更接近真实数据分布的高质量图像。

4. 结语

本研究基于生成对抗网络(GAN)技术,针对医疗影像中数据不足的问题,设计并实现了一种基于改进生成对抗网络结构的肺结节数据增扩方法。采用了 DCGAN 和 WGAN-GP 两种网络结构,并在 LIDC-IDRI 公开数据集上进行了实验验证。实验结果表明,使用生成对抗网络能够生成质量较高的肺结节影像数据,并且在采用 WGAN-GP 网络相较于 DCGAN 网络在生成肺结节影像方面表现出更好的性能。生成对抗网络技术在解决医疗影像数据不足问题方面具有比较好的应用前景。今后可以进一步优化模型结构,以提高生成图像的质量和多样性。

基金项目

国家级大学生创新创业训练项目(202311058020)。

参考文献

- [1] 何炼红, 王志雄. 人工智能医疗影像诊断侵权损害赔偿法律问题[J]. 政治与法律, 2020(3): 27-37.
- [2] 梁俊杰, 韦舰晶, 蒋正锋. 生成对抗网络 GAN 综述[J]. 计算机科学与探索, 2020, 14(1): 1-17.
- [3] Goodfellow, I., Pouget-Abadie, J., Mirza, M., *et al.* (2014) Generative Adversarial Nets. arXiv: 1406.2661.
- [4] 徐晨, 张志强. 生成对抗网络研究现状综述[J]. 信息系统工程, 2021(10): 150-152.
- [5] 胡雅妮, 李光亚, 韩晓, 等. 基于双判别生成对抗网络的壁画图像虚拟修复[J]. 国外电子测量技术, 2022, 41(6): 14-19.
- [6] 李易达. 基于生成对抗网络的图像补全算法研究[D]: [硕士学位论文]. 北京: 北京建筑大学, 2022.
- [7] 马咏莉. 基于注意力机制生成对抗网络的图像复原[D]: [硕士学位论文]. 烟台: 烟台大学, 2022.
- [8] 刘强. 基于生成对抗网络的图像修复方法研究[D]: [硕士学位论文]. 吉林: 东北电力大学, 2022.
- [9] 汪强. 基于生成对抗网络的兵马俑色彩复原[D]: [硕士学位论文]. 西安: 西北大学, 2022.
- [10] 熊景琦. 基于生成对抗网络的低剂量 CT 图像去噪[D]: [硕士学位论文]. 无锡: 江南大学, 2022.
- [11] 高文波. 基于改进生成对抗网络的低剂量 CT 图像降噪方法研究[D]: [硕士学位论文]. 太原: 中北大学, 2022.
- [12] 欧阳婉卿. 基于生成对抗网络的低剂量 CT 图像去噪算法研究[D]: [硕士学位论文]. 湘潭: 湖南科技大学, 2021.
- [13] 游森榕. 基于生成对抗网络的医学影像重建技术[D]: [硕士学位论文]. 北京: 中国科学院大学(中国科学院深圳先进技术研究院), 2022.
- [14] 李锦欣. 基于生成对抗网络的医学图像超分辨率重建[D]: [硕士学位论文]. 西安: 西安电子科技大学, 2021.
- [15] 沈博. 基于生成对抗网络的核磁共振图像重建研究[D]: [硕士学位论文]. 西安: 西安电子科技大学, 2021.
- [16] Radford, A., Metz, L. and Chintala, S. (2016) Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks. arXiv: 1511.06434. <https://arxiv.org/pdf/1511.06434.pdf>
- [17] 孟辰, 曾志高, 朱艳辉, 等. 改进生成对抗网络在图片数据生成中的应用[J]. 计算机工程与应用, 2022, 58(15): 260-269.
- [18] Gulrajani, I., Ahmed, F., Arjovsky, M., *et al.* (2017) Improved Training of Wasserstein GANs. arXiv: 1704.00028.
- [19] Wei, X., Gong, B., Liu, Z., *et al.* (2018) Improving the Improved Training of Wasserstein GANs: A Consistency Term and Its Dual Effect. arXiv: 1803.01541.
- [20] Armato III, S.G., McLennan, G., Bidaut, L., *et al.* (2011) The Lung Image Database Consortium (LIDC) and Image Database Resource Initiative (IDRI): A Completed Reference Database of Lung Nodules on CT Scans. *Medical Physics*, **38**, 915-931.
- [21] Xu, Q., Huang, G., Yuan, Y., *et al.* (2018) An Empirical Study on Evaluation Metrics of Generative Adversarial Networks. arXiv: 1806.07755.