

基于Ano-GAN模型的医学图像缺陷检测研究

——以MRI影像为例

史丽琴*, 王仲平#, 程正祥

兰州交通大学数理学院, 甘肃 兰州

收稿日期: 2023年9月25日; 录用日期: 2023年10月18日; 发布日期: 2023年10月25日

摘要

图像异常检测是计算机视觉中重要的研究课题, 本文主要就MRI医学影像展开研究, 致力于提高机器诊断疾病的效率, 主要选取人体膝关节的MRI数据进行实验, 研究Ano-GAN模型在MRI数据上的缺陷检测效果。通过多次对比实验, 就软件最优模型输出的切片影像及生成器和判别器网络的损失, 不断调整模型网络的层数及相关参数, 从而得到最优模型, 并通过最优模型输出的结果, 分析模型对数据的检测效果, 分析模型在该类数据检测当中的效果及普遍MRI医学影像检测的适用程度, 对于提高深度学习模型在异常检测领域的发展有重要意义。

关键词

MRI影像, DCGAN, 缺陷检测, 图像拟合

Research on Medical Image Defect Detection Based on Ano GAN Model

—Taking MRI Imaging Data as an Example

Liqin Shi*, Zhongping Wang#, Zhengxiang Cheng

School of Mathematics and Physics, Lanzhou Jiaotong University, Lanzhou Gansu

Received: Sep. 25th, 2023; accepted: Oct. 18th, 2023; published: Oct. 25th, 2023

Abstract

Image anomaly detection is an important research topic in computer vision. This article mainly

*第一作者。

#通讯作者。

文章引用: 史丽琴, 王仲平, 程正祥. 基于 Ano-GAN 模型的医学图像缺陷检测研究[J]. 应用数学进展, 2023, 12(10): 4403-4414. DOI: 10.12677/aam.2023.1210433

focuses on MRI medical images, aiming to improve the efficiency of machine diagnosis of diseases. It mainly selects MRI data of human knee joints for experiments to study the defect detection effect of the Ano-GAN model on MRI data. Through multiple comparative experiments, we continuously adjust the number of layers and related parameters of the model network to obtain the optimal model based on the slice images output by the software's optimal model, as well as the losses of the generator and discriminator network. Through the results of the optimal model output, we analyze the model's detection effect on data, its effectiveness in detecting such data, and its applicability in general MRI medical image detection. It is of great significance for improving the development of deep learning models in the field of anomaly detection.

Keywords

MRI Imaging, DCGAN, Defect Detection, Image Fitting

Copyright © 2023 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

异常检测的主要任务是识别不符合总体数据分布的数据样本。随着深度学习的发展,已经有很多学者将深度学习应用到物体瑕疵检测中,如列车钢轨的缺陷检测、医学影像中各种疾病的检测。但是瑕疵检测任务几乎都存在一个共同的难题:缺陷数据太少了。使用这些稀少的缺陷数据很难利用深度学习训练一个理想的模型,往往都需要进行数据扩充,即通过某些手段增加我们的缺陷数据[1]。GAN网络也是实现数据扩充的主流手段,在漫长的研究中,研究者纷纷考虑能不能使用一种无监督的方法来实现缺陷检测[2] [3]。

目前主流的深度学习模型是在计算机通用视觉领域发展起来的,先是对行人的检测,后定位车辆或在照片中区分猫和狗。医学影像分析研究固然重要,但与这些研究是存在差异的,其中包括CT和MR图像本身的大小和像素格式的差异,日常照片是2D和彩色的,也包括测试对象大小的差异。虽然疾病辅助检查的目标相对较小,只在图像中占据较小的区域,但人们对日常照片的关注往往是占据图像主要区域的大目标。因此,本文选择人类膝关节MRI图像和深度学习模型进行研究。分析深度学习相关模型在医学MRI图像病变检查中的可行性具有现实意义。

2. 数据及相关原理介绍

2.1. 数据描述

本文选取的MRNet数据集[4]来自官网:<https://stanfordmlgroup.github.io/>,数据包括了2001年1月1日至2012年12月31日期间在斯坦福大学医学中心进行的1370次膝关节MRI检查,平均年龄在38.0岁;且其中569例为女性患者。

该数据集包含1104次异常检查,其中319次交叉韧带撕裂和508次半月板撕裂,且从每次检查中提取矢状面T2(sagittal plane T2-weighted series),冠状面T1(coronal plane T1-weighted series)以及轴面PD(axial plane PD-weighted series)三种模态,如图1所示。为了对病例做出正确的决定,放射科医生通常会从不同的平面查看MRI扫描,以便有一个全局的视野。整个数据集分为训练集:1130例,1088名患者、验证集120例、111名患者,如表1所示,在这里将验证集暂且作为测试集开展研究。




Figure 1. MRNet data slice view

图 1. MRNet 切片视图

MRI [5]是一种用于放射学的医学成像技术，用于形成身体解剖结构和生理过程的图像。与 CT 图像非常相似，二者都是“数字图像”，并以不同灰度显示不同结构的解剖和病理的断面图像。与 CT 一样，磁共振成像也几乎适用于全身各系统的不同疾病，例如肿瘤、炎症、创伤、退行性病变，以及各种先天性疾病等的检查。磁共振成像无骨性伪影，可随意作直接的多方向切层，对颅脑、脊柱和脊髓等的解剖和病变的显示，尤优于 CT。核磁共振成像利用磁场产生身体的详细图像。

Table 1. MRNet dataset distribution

表 1. MRNet 数据集分布

MRI 模态分类	训练集	测试集
axial plane	1130	120
sagittal plane	1130	120
coronal plane	1130	120

MRI 的 T1、T2 方向切层是用于测量电磁波的物理量，它们可以用作成像数据。基于 T1 制作的影像被称为“T1 加权影像”，在临床工作中缩写为“T1”，T2 也是如此。从解剖结构上看，T1 成像的整体感觉与“临床成像”的“习惯性配色风格”非常相似，可以看到各种截面解剖图像。在观察病变时，T2 的信号与含水量有关。许多病变具有比周围正常组织更强的 T2 信号，通常表现为明亮。在序列中，可以清楚地看到病变的位置和大小等详细信息。

2.2. 生成式对抗网络原理

生成对抗网络[6]是由 Good-fellow 等人提出的作为训练生成模型的框架，也是实现数据扩充的一种主流手段，学者们一直都在考虑能不能使用一种无监督的方法来实现缺陷检测，2017 年 AnoGAN 模型[7]得以提出，它不需要缺陷数据进行训练，而仅使用正常数据训练模型。GAN 框架通常涉及两个模型：生成器 G 和鉴别器 D 。两个模型同时训练，在训练过程中，鉴别器将数据样本分类为真假，而生成器试图通过生成与真实数据样本相似的假数据样本来“愚弄” D 。原始 GAN 框架同时具有 G 和 D 求解相同的值函数。

GAN 模型的数学原理[8]：针对 GAN 的目标，假定用于生成的噪声分布是 $p_z(z)$ ，真实数据分布是 $p_x(x)$ ，同时生成器和判别器分别为 G 和 D ，则 GAN 的目标可以通过如下公式描述：

$$\min_G \max_D V(D, G) = \mathbb{E}_{x \sim p_{data}(x)} \left[\log D(x) + \mathbb{E}_{z \sim p_z(z)} \left[\log(1 - D(G(z))) \right] \right] \quad (1)$$

这里的公式形式和常见的交叉熵损失函数非常相似，只是没有负号。 $D(x)$ 表示 x 来源于真实数据的分布，理想情况下有： $D(x) = 1, \log D(x) = 0$ 。

如果分类器不是很理想， $D(x)$ 就输出越小， $\log D(x)$ 则会越小。 $G(z)$ 表示噪声经过生成器后生成的样本， $D(G(z))$ 则是分类器认为生成样本属于真实样本的概率，理想情况下这个数值为 0，但当性能越

不好, $D(G(z))$ 越大, $\log(1-D(z))$ 就会越小。总之, 后面两项期望的和越大, 分类器识别能力越好。再观察估值函数 $V(D, G)$ 前面的 \min/\max 就很明显, 而最终的一个目标是求外面的 $\min G$, G 的目标是让 V 最小; 而内部嵌套的 $\max D$, 则代表 D 是在 G 给定的情况下, 最大化 V , 即给定生成器, 得到识别能力最好的分辨器。

得到了 GAN 的数学化建模后还有一个问题: 假设 G 和 D 有足够的容量(没有参数限制), 此时问题是不是有解的。分两步来求解: 在 G 固定的情况下, 求出最佳的分类器 D_G^* ; 然后将最佳分类器带回, 证明该问题的有解性。第一步: 求最优 D 展开并对第二项进行换元

$$\begin{aligned} V(D, G) &= \int_x p_{data}(x) \log D(x) dx + \int_z p_z(z) \log(1-D(g(z))) dz \\ &= \int_x p_{data}(x) \log D(x) + p_g(x) \log(1-D(g(z))) dx \end{aligned} \tag{2}$$

第一行实际上就是原有的 $V(G, D)$ 对期望公式的展开。第二行如何得到, 一个直观的思路是令 $g(z) = x$, 并进行换元。这里的 $p_g(x)$ 实际上代表了由 z 生成的 x 的分布, 和二者都有联系。完整的推导相对繁琐, 按照原文中的符号, 令: $p_{data}(x) = a, p_g(x) = b, D(x) = y$, 得到积分内的积分函数:

$$f(y) = a \log(y) + b \log(1-y) \tag{3}$$

再对 $f(y)$ 求一阶导和二阶导, 并求出极值点:

$$f'(y) = \frac{a}{y} - \frac{b}{1-y} \tag{4}$$

$$f'(y) = 0 \Rightarrow y = \frac{a}{a+b} \tag{5}$$

$$f''(y) = -\frac{a}{y^2} - 0 - \frac{b}{(1-y)^2} < 0 \tag{6}$$

$a/(a+b)$ 是极值点, 而由于二阶导恒小于 0, 该极值点是最大值, 且 $f(y)$ 有且仅有这一个最大值。则有:

$$V(D, G) = \int_x f(y) dx \leq \int_x \max_y f(y) dx \tag{7}$$

当 x 变换的时候, 对于每个 x , y 都可以取到相应的唯一最大值, 因此等号可以取到, 当且仅当 $y = a/(a+b)$ 得到的, 即:

$$D(x) = \frac{p_{data}(x)}{p_{data}(x) + p_g(x)} \tag{8}$$

第二步: 求最优 G , 令最优生成器为 D_G^* , 此时, $V(G, D)$ 由于 D 已经固定, 转化为根据 G 求最小值位置。再令:

$$\begin{aligned} C(G) &= \int_x p_{data}(x) \log D^G(G) + p_g(x) \log(1-D_G^*) \\ &= \int_x p_{data}(x) \log \frac{p_{data}(x)}{p_{data}(x) + p_g(x)} + p_g(x) \log \left(\frac{p_g(x)}{p_{data}(x) + p_g(x)} \right) \\ &= -\log 4 + \int_x p_{data}(x) \log \frac{p_{data}(x)}{p_{data}(x) + p_g(x)} + p_g(x) \log \left(\frac{p_g(x)}{p_{data}(x) + p_g(x)} \right) \end{aligned} \tag{9}$$

这里通过添加分母 2，构造了两个 KL 散度，而 KL 散度是大于等于 0 的。并且，假设存在两个分布 A 和 B ，且这两个分布的平均分布 $C = (A+B)/2$ ，则它们之间的 JS 散度是 A 与 C 的 KL 散度和 B 与 C 的 KL 散度的二分之一，即：

$$JSD(A\|B) = \frac{1}{2}KL(A\|C) + \frac{1}{2}KL(B\|C) \quad (10)$$

因此，有：

$$\begin{aligned} C(G) &= -\log 4 + KL\left[p_{data}(x) \left\| \frac{p_{data}(x) + p_g(x)}{2} \right.\right] \\ &\quad + KL\left[p_g(x) \left\| \frac{p_{data}(x) + p_g(x)}{2} \right.\right] \\ &= -\log 4 + 2JS(p_{data}(x) \| p_g(x)) \end{aligned} \quad (11)$$

由 JS 散度的性质，当且仅当 $p_{data}(x) = p_g(x)$ 的时候， $C(G)$ 取到最小值 $-\log 4$ 。可以发现，此时最优生成器恰好恒为 $1/2$ ，这和最开始的猜想一致。这也证明了这一优化问题是有解的以及最优分类器的解最终收敛到 $1/2$ 。在实际应用中，尤其是 DNN 中， G 和 D 都不能用数学描述，但是解的存在性可以得出在训练当中可以不断逼近最优解来得到近似最优解。

2.3. DCGAN 网络原理

DCGAN [9] 也就是深度卷积对抗网络，它的主要是在网络架构上改进了原始 GAN，DCGAN 的生成器与判别器都利用 CNN 架构替换了 GAN 原来的全连接网络，同时 DCGAN 的生成器网络和判别器网络都去除了 CNN 当中的池化层，判别器保留 CNN 的整体架构，生成器则是将卷积层替换成了反卷积层或者叫转置卷积层。在判别器网络和生成器网络中在每一层之后都是用 BN 层，实际上这有助于处理初始化不良而导致的一些模型训练过程中出现的问题，能够加快模型的训练速度，提升训练的稳定性。利用 1×1 卷积层替换到所有的全连接层。在生成器中除输出层使用 Tanh (Sigmoid) 激活函数，其余层全部使用 ReLU 激活函数。在判别器所有层都使用 LeakyReLU 激活函数。

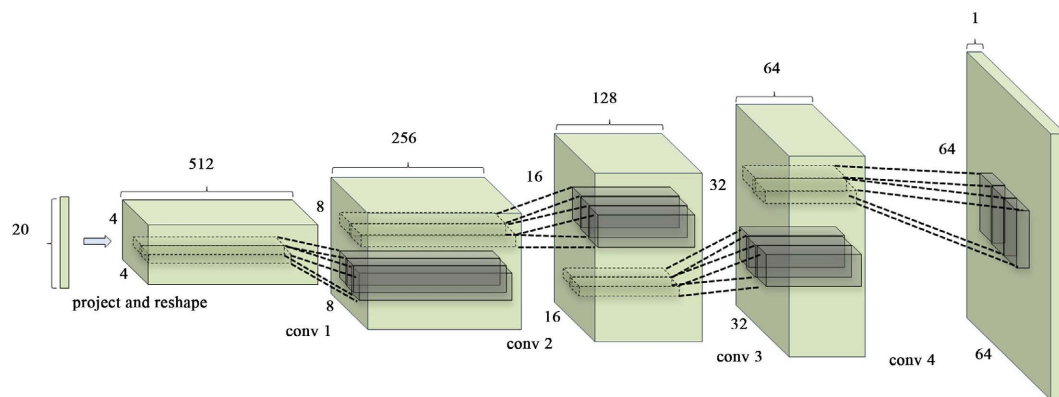


Figure 2. Schematic diagram of generator network for DCGAN

图 2. DCGAN 的生成器网络原理图

如图 2 这里的 conv 实际上是 deconv，也就是 Pytorch 当中的 Convtranspose。deconv 的前向和 conv 的后向传播非常相像。如果从后往前地看待这个生成器，就会发现，这是一个非常典型的卷积神经网络，

使用 conv 卷积，特征图逐渐减小而且通道数逐渐增加。且研究者认为使用 DNN 的 GANs 应该遵循如下原则：

- 1) 使用 stride 来替代 pooling，而且不能有全连接层；
- 2) G 和 D 中都要使用 BN；
- 3) G 中所有的层的激活函数都使用 ReLU，但是最后一层使用 Tanh 约束生成图像的范围；
- 4) D 中所有层的激活函数都使用 LeakyReLU，但是最后一层使用 Sigmoid 输出概率。

下采样主要目标是创建与屏幕区域大小相匹配的图像缩略图。例如，比如说在 CNN 中得池化层或卷积层就是下采样。不过卷积过程导致的图像变小是为了提取特征，而池化下采样是为了降低特征的维度。而上采样实际上就是放大图像，增加图像特征，指的是任何可以让图像变成更高分辨率的技术。在这一点上，可以看到为什么可以使用噪声在网络上生成图像。

2.4. 技术特点分析

通过 MRI 的数据特点，异常病变数据具有罕见、稀少的特点，因此在模型的大框架上，GAN 模型的数据扩充特性使其成为本文研究的第一选择，也可以说 GAN 模型对于 MRI 这个特殊数据的异常检测具有较高的适配性。而 DCGAN 在原模型的技术上进行的改进，加快了模型的训练速度，提升了训练的稳定性。因此选择 DCGAN 作为模型的内核所在进行 MRI 影像的缺陷检测研究，并判断其检测的模型效果，分析其在机器辅助医疗诊断方面的可行性及效果。

3. 实验过程

3.1. 实验原理

在生成式对抗网络和 DCGAN 的原理基础上，本文 AnoGAN 模型是分两个阶段进行的，如图 3 所示：首先是训练阶段，然后是测试阶段，训练阶段仅使用正常的的数据训练对抗生成网络。如使用训练集中无异常的 MRI 切片作为本阶段的数据进行训练，也就是正常数据。训练结束后输入一个向量 z ，生成网络会将 z 变成正常数据。这个阶段也就是 DCGAN [10] [11]。训练阶段已经训练好 GAN 网络，后面的测试阶段 GAN 网络的权重将不再变换。测试阶段：就是要利用训练好的网络来进行缺陷检测。

例如有一些 MRI 病变影像的切片，记为 1，此为缺陷数据，训练时使用正常切片进行训练，记为 0。接着要做的就是搜索一个潜在变量并让其生成的影像与正常影像尽可能接近。然后计算生成的 $G(z)$ 与缺陷切片的损失。




Figure 3. Experimental design flow chart
图 3. 实验设计流程图

3.2. 模型框架设计

模型的框架如图 4 所示，主要分为(a)生成器网络和(b)判别器网络。具体实现如下：先定义一个潜在变量 z ，然后经过之前训练的好的生成网络，得到假图像 $G(z)$ ，接着 $G(z)$ 和缺陷数据“1”计算损失，这

时候损失往往会比较大，通过不断的更新 z 值，使损失不断的减少，在程序中设置更新 z 的次数，如更新 5000 次后停止，此时将如今的潜在变量 z 送入生成网络得到的假图像已经和图片“1”非常像了，便将 z 再次送入生成网络，得到 $G(z)$ 。

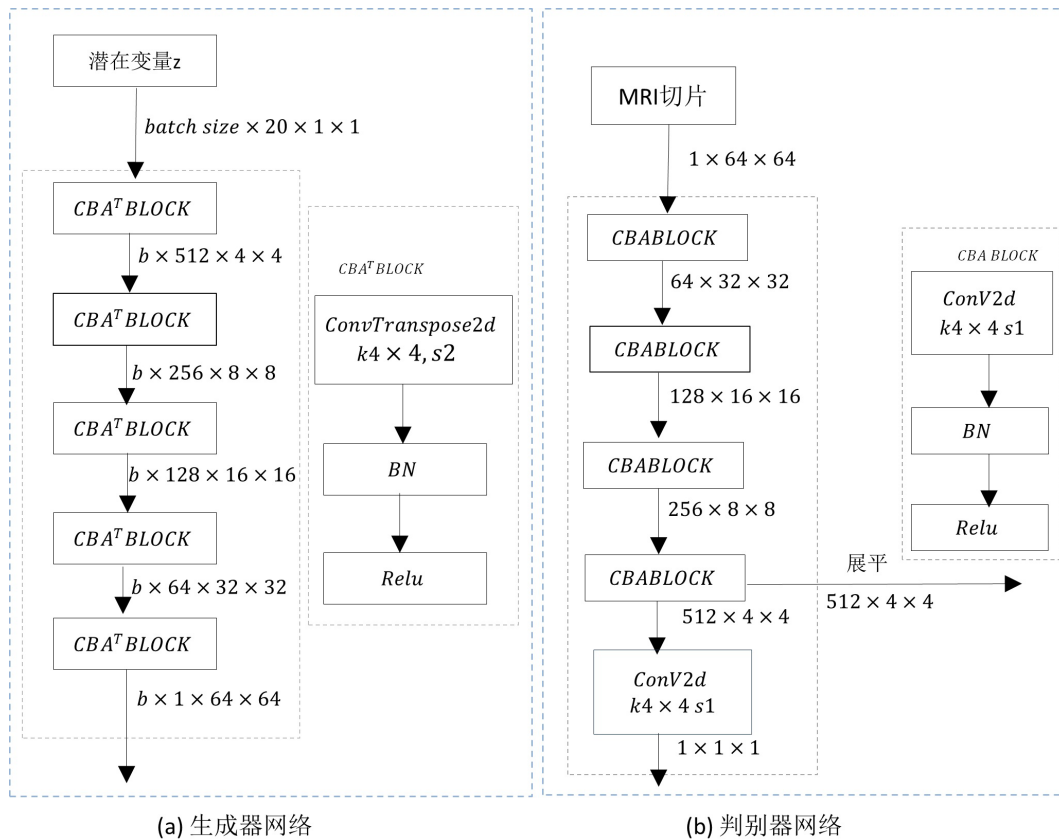


Figure 4. Model network framework diagram
图 4. 模型网络框架示意图

由于潜在变量 z 送入的网络是生成正常切片的，尽管通过搜索使 $G(z)$ 和“1”尽可能相像，但还是存在一定差距，即它们的损失较大，最后就可以计算 $G(z)$ 和图片 1 的损失，并将这个损失作为判断是否有缺陷的重要依据。在测试阶段传入的不是缺陷数据，而是正常的的数据“0”，此时应用相同的方法搜索潜在变量 z ，然后将最终的 z 送入生成网络，得到 $G(z)$ ，最后计算 $G(z)$ 和图片“0”的损失。由于潜在变量 z 送入的网络是生成图片“0”的，所以最后生成的 $G(z)$ 可以和数据“0”很像，它们的损失较小。而实际上生成器和判别器就是一个 DCGAN 网络。测试阶段的难点就在于定义损失函数来更新 z 值，此部分的损失，主要分为两部分，即 Residual Loss 和 Discrimination Loss，其中 Residual Loss 定义：

$$R(z) = \sum |x - G(z)| \tag{12}$$

上式 z 表示潜在变量， $G(z)$ 表示生成的假图像， x 表示输入的测试图片。上式表示生成的假图像和输入图片之间的差距。如果生成的图片越接近 x ，则 $R(z)$ 越小。Discrimination Loss 定义：

$$D(z) = \sum |f(x) - f(G(z))| \tag{13}$$

上式 z 表示潜在变量， $G(z)$ 表示生成的假图像， x 表示输入的测试图片。 $f(*)$ 表示将*通过判别器，

然后取判别器某一层的输出结果。这里使用的其实是判别器某层的输出，可以把判别器当作一个特征提取网络，将生成的假图片和测试图片都输入判别器，看它们提取到特征的差异。同样，如果生成的图片越接近 x ，则 $D(z)$ 越小。

求得 $R(z)$ 和 $D(z)$ 后，定义它们的线性组合作为最终的损失，如下：

$$\text{loss}(z) = (1 - \lambda)R(z) + \lambda D(z) \quad (14)$$

而通常取 $\lambda = 0.1$ 来求总的损失。

3.3. 实验设置

Table 2. Experimental design

表 2. 实验设计

实验序号	数据类型	简称	模型	训练集	测试集
1	axial plane_ACL	PD_ACL	conv4	6000	1000
2	axial plane_meniscus	PD_m	conv4	6000	1000
3	sagittal plane_ACL	T2_ACL	conv4	6000	1000
4	sagittal plane_meniscus	T2_m	conv4	6000	1000
5	coronal plane_ACL	T1_ACL	conv4	3000	1000
6	coronal plane_meniscus	T1_m	conv4	6000	1000

设计的 6 次模拟实验涉及到了对三种不同模态数据，及前交叉韧带(ACL)撕裂与半月板撕裂这两种疾病数据的全面覆盖，如表 2 所示，对于 PD、T2 类型的切片实验都从样本中随机抽取 6000 张影像作为训练集训练模型，测试集则设定为 1000 张，而 T1 方向切片数据实验分为交叉韧带撕裂和半月板撕裂，对于训练集的设置分别为 3000 和 6000。模型设置为 CONV4 代表生成器网络和判别器网络的层数，因而就该数据的缺陷检测来说，模型因此得到的实验结果能够更具说服力。

4. 结果分析

正如前一章的实验设计，通过 PyCharm3.7 进行实验，主要用到了 Torch 框架。首先不断调整训练集和测试及的数据比例，进行模型参数调整，以及模型生成器和判别器网络层数的设置，通过观察不同参数及模型生成的效果图及模型损失来调整，最终得出相对最优的模型及参数。

4.1. 模型影像分析

将设计的 6 次实验，分别在训练好的模型上进行实验。实验一：选取数据 PD_ACL 训练集 6000，测试集 1000，迭代 300 次得到模型生成器输出的影像，如图 5(a)所示；选取数据 PD_m 训练集 6000，测试集 1000，迭代 300 次得到模型生成器输出的影像，如图 5(b)所示；实验三：选取数据 T2_ACL 训练集 6000，测试集 1000，迭代 300 次得到模型生成器输出的影像，如图 5(c)所示；实验四：选取数据 T2_m 训练集 6000，测试集 1000，迭代 300 次得到模型生成器输出的影像，如图 5(d)所示；实验五：选取数据 T1_ACL 训练集 3000，测试集 1000，迭代 300 次得到模型生成器输出的影像，如图 5(e)所示；实验六：选取数据 T1_m 训练集 6000，测试集 1000，迭代 300 次得到模型生成器输出的影像，如图 5(f)所示。可以看出这六次实验得出的结果相对来说是比较好的，这 6 张模型生成的 MRI 影像与实际的 MRI 已十分接近。其中 T1 由于数据本身的限制，选取了训练集为 3000，是其他实验训练集的一半，可以看到 e 图的效果也很好，所以训练集 3000 就足以用来训练模型了。

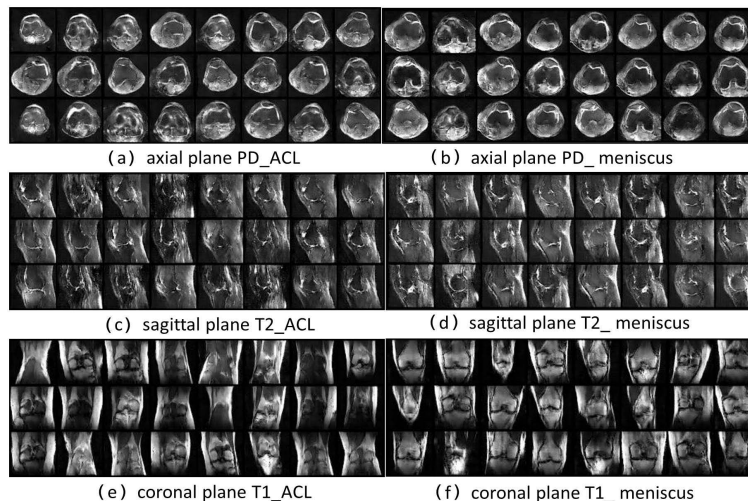


Figure 5. Generator network output image diagram

图 5. 生成器网络输出影像示意图

4.2. 模型损失分析

4.2.1. 生成器网络实验损失

从图 6 可以看到模型训练生成器损失迭代的收敛情况还是较为不错的，因此我们的模型的训练效果还是比较好的，这 6 次实验里，对所设置的训练集的膝关节的 MRI 切片进行 300 次训练后可以说模型已达到最优。从图模型训练损失波动图可以看出在 D_{loss} 在迭代 150 次后损失已趋于稳定，在 0~0.1 之间上下波动，这 6 次实验整体的一个趋势是前 100 次迭代波动幅度较大，200 次以后，生成器的损失上下波动已趋于平稳。

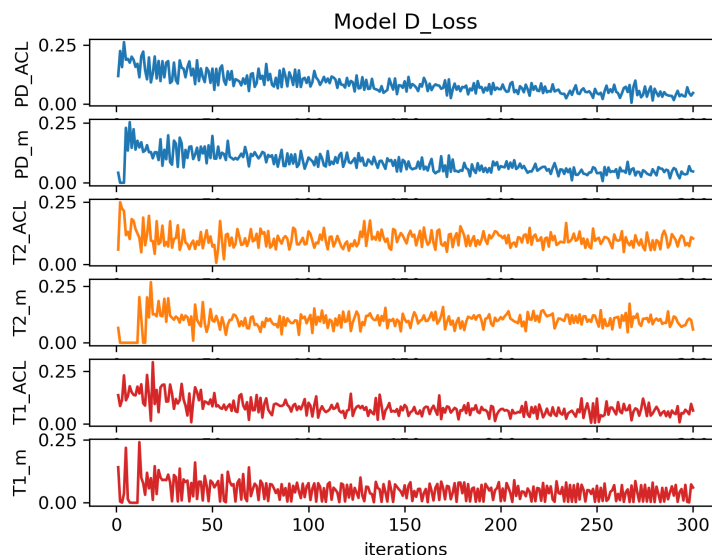


Figure 6. Model generator network experimental loss fluctuation diagram

图 6. 模型生成器网络实验损失波动示意图

4.2.2. 判别器网络实验损失

从图 7 可以看到模型训练判别器损失迭代的收敛情况还是较为不错的，因此我们的模型的训练效果

还是比较好的，这 6 次实验里，对所设置的训练集的膝关节的 MRI 切片进行 300 次迭代。从图模型训练损失波动图可以看出在 G_loss 在迭代 100 次后损失已趋于稳定，在较小的范围之间上下波动，这 6 次实验整体的一个趋势是前 50 次迭代波动幅度较大，100 次以后，判别器网络的损失已趋于稳定。

其中前交叉韧带撕裂数据的三次实验判别器网络的损失整体偏高，在 2~4 之间上下波动，且 PD_ACL 的 G_loss 随着迭代有一个缓慢向上增长的趋势，而半月板撕裂的三次实验中，判别器损失稳定在 1~3 之间，特别是 T1_m 的判别器损失在 1.5 左右上下波动，趋于平稳。




Figure 7. Model discriminator network experimental loss fluctuation diagram
图 7. 模型判别器网络实验损失波动示意图

4.2.3. 局部异常得分

接着对 6 次实验的模型测试集随机抽取的 16 个切片进行训练，通过生成器生成新图像，并计算他们的损失，如图 8 所示，分别是 6 次实验中测试集生成的 MRI 影像切片视图，可以看到随机抽取的切片得到的生成图像相对清晰，ACL 数据整体输出的影像与实际的切片相似度更高。

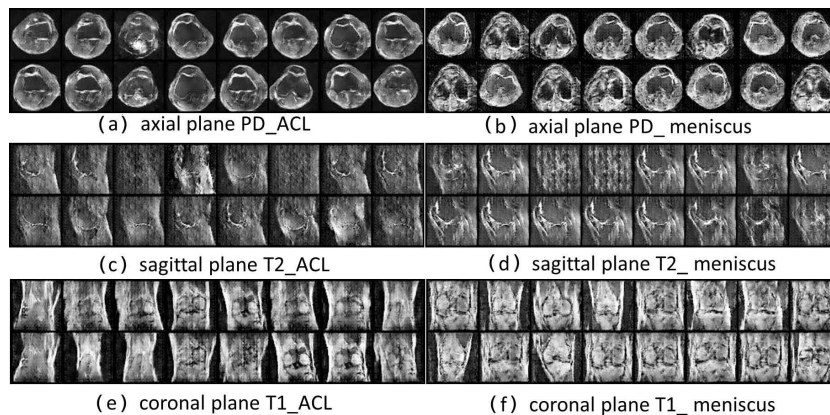


Figure 8. Image representation generated from sample extraction in the test set
图 8. 测试集中抽取样本生成的影像示图

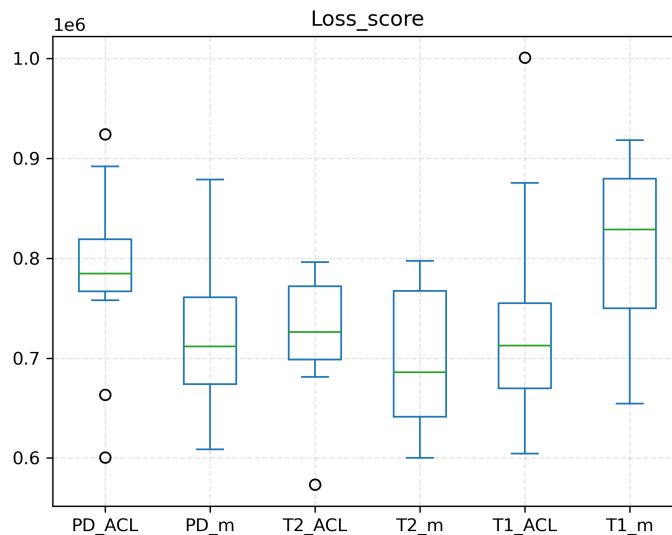


Figure 9. Experimental sample extraction abnormal score box chart
图 9. 实验抽取样本异常得分箱线图

图 9 是 6 次实验中模型测试集随机抽取的 16 个切片影像异常得分的数据的损失得分箱线图, 可以看到随机抽取的切片测试得到的异常得分较为稳定, 只有个别异常值的存在, 如在 PD_ACL 类型数据上进行的实验, 整体得分分布的还是比较紧密, 就是存在 3 个异常值, 其中 PD_m、T2_ACL、T2_m、T1_ACL 这四次实验输出的得分相比差异不大, 整体分布的范围也相差不大, T2_m 相对其他三个较为分散, 且 T2_ACL 含有一个最低的异常值, T1_m 是 6 次实验中异常得分分布整体较高的, 这与其数据特征或许有较大关系。总体上看, 模型的缺陷检测结果变动幅度还是较为稳定的。

5. 总结

本文主要就 MRI 医学影像的缺陷检测展开研究, 选取官网数据: 人体膝盖部位的 MRNet, 根据数据患病的类型, 前交叉韧带(ACL)撕裂与半月板撕裂这两种, 将数据集分 6 次进行实验, 分别划分训练集和测试集, 在迭代 300 次以后, 对比 Ano-GAN 模型生成器网络输出的 MRI 切片影像, 观察影像效果; 同时分析模型迭代过程生成器网络和判别器网络的损失波动情况来分析模型效果: 6 次实验之间的损失波动图存在些许差异, 但生成器和判别器的损失波动在实验迭代一定次数后皆趋于平稳, 同时判别器的损失在数值上整体高于生成器的损失。接着研究 6 次实验中, 分别从测试集随机抽取的 16 个切片影像在模型训练迭代 5000 次, 所得到的异常得分数据的损失箱线图, 可以看到随机抽取的切片测试得到的异常得分较为稳定, 只有个别异常值的存在, 选取数据的不同得到的效果存在些许差异, 但是整体的效果还是比较稳定。

而因为本文主要是针对数据集为人体膝关节前交叉韧带撕裂和半月板损伤的数据集 MRnet 进行的实验, 尽管模型的效果较好, 实验设计也相对合理, 但是依然存在数据的偶然性, 或许在其他的医学 MRI 影像数据集上的效果有待考究, 因而不排除这种特殊情况, 即缺乏通用性的探讨, 模型可能缺乏对不同操作条件的概括, 对于未验证过的数据集, 可能存在性能上或多或少的差异。

参考文献

- [1] 吕承侃, 沈飞, 张正涛, 等. 图像异常检测研究现状综述[J]. 自动化学报, 2022, 48(6): 1402-1428.
- [2] 李少波, 杨静, 王铮, 等. 缺陷检测技术的发展与应用研究综述[J]. 自动化学报, 2020, 46(11): 2319-2336.

-
- [3] 汤勃, 孔建益, 伍世虔. 机器视觉表面缺陷检测综述[J]. 中国图象图形学报, 2017, 22(12): 1640-1663.
- [4] 阿斯科纳 D, 麦吉尼斯 K, 斯米顿 A F. 利用 MRNet 数据集检测膝关节损伤的现有和新的深度学习方法的比较研究[C]//2020 智能数据科学技术与应用国际会议(IDSTA). 2020: 149-155.
- [5] Hashemi, R.H., Bradley, W.G. and Lisanti, C.J. (2012) MRI: The Basics. Lippincott Williams & Wilkins, Philadelphia.
- [6] Goodfellow, J., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A. and Bengio, Y. (2014) Generative Adversarial Nets. *Advances in Neural Information Processing Systems*, **27**.
- [7] Schlegl, T., Seeböck, P., Waldstein, S.M., *et al.* (2017) Unsupervised Anomaly Detection with Generative Adversarial Networks to Guide Marker Discovery. In: Niethammer, M., *et al.*, Eds., *International Conference on Information Processing in Medical Imaging*, Springer International Publishing, Cham, 146-157. https://doi.org/10.1007/978-3-319-59050-9_12
- [8] Wang, Y. (2020) A Mathematical Introduction to Generative Adversarial Nets (GAN). arXiv:2009.00169, 2020.
- [9] Radford, A., Metz, L. and Chintala, S. (2015) Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks. arXiv:1511.06434.
- [10] Fang, W., Zhang, F., Sheng, V.S., *et al.* (2018) A Method for Improving CNN-Based Image Recognition Using DCGAN. *Computers, Materials & Continua*, **57**, 167-178. <https://doi.org/10.32604/cmc.2018.02356>
- [11] Wu, Q., Chen, Y. and Meng, J. (2020) DCGAN-Based Data Augmentation for Tomato Leaf Disease Identification. *IEEE Access*, **8**, 98716-98728. <https://doi.org/10.1109/ACCESS.2020.2997001>