



華東師範大學

East China Normal University

基于 U-Net 有关 COVID-19 的肺炎分割

姓 名： 周俪檬、朱张喆

学 号： 10204511412

10215304464

学 院： 软件工程学院

专 业： 软件工程

任课教师： 曹桂涛

职 称： 教授

2024 年 6 月

目录

1 引言	1
2 相关工作	2
3 相关基础知识	3
3.1 用于肺炎分割的深度学习模型.....	3
3.2 肺炎分割的评价标准.....	5
4 模型优化	8
4.1 ResNet.....	8
4.2 Swin Transformer.....	8
4.2.1 Swin Transformer 与 ViT 的区别.....	8
4.2.2 Swin Transformer 的网络结构.....	9
4.2.3 SW-MSA.....	10
4.3 网络结构.....	11
5 实验分析	12
5.1 数据集.....	12
5.2 DICE.....	13
5.2.1 U-Net 与 UResnet 的训练比较.....	13
5.2.2 UResnet 优化带来的具体改进.....	13
5.3 F1.....	14
5.3.1 U-Net 与 UResnet 的训练比较.....	14
5.3.2 UResnet 优化带来的具体改进.....	15
5.4 IOU.....	15
5.4.1 U-Net 与 UResnet 的训练比较.....	15
5.4.2 UResnet 优化带来的具体改进.....	16

5.5 混淆矩阵	17
5.5.1 U-Net 与 UResnet 的训练比较	17
5.5.2 UResnet 优化带来的具体改进	18
5.5.3 混淆矩阵小结	18
5.6 实验预测图	19
6 图像处理系统	20
参考文献	21

摘要

本项目旨在识别出 CT 肺窗中感染 Covid-19 的区域，在 U-Net 的基础上通过增加 Swin Transformer 和 ResNet 模块进行小目标检测。在实验中通过对比基于 U-Net 与 UResnet，我们发现改进后的模型在进行识别肺炎感染区域的问题上有显著提升，但是仍存在一定的误差需要改进。最后，我们将数字图像基础功能与肺炎分割整合成一个系统。

关键词：肺炎分割，自注意力机制，残差网络，小目标检测

1 引言

肺炎是指发生在肺部的炎症，是一种常见的急性呼吸系统疾病。2020年初在全球大范围传播流行的 COVID-19 由于其高传染性且有可能引起严重后果的疾病被 WHO 认定为国际关注的突发公共卫生事件 PHEIC。COVID-19 与其他肺炎之间的区别主要在于其病因和传染性。COVID-19 是由一种新型冠状病毒 SARS-CoV-2 引起的，而其他类型的肺炎则可能由不同的病原体引起，包括细菌、真菌等。COVID-19 具有较高的传播性，尤其是在无症状感染者中，这让它更容易在社区中广泛传播。相较于一些常见的肺炎，COVID-19 可能导致更严重的疾病。因此，研究 COVID-19 有助于加深对其传播机制和致病性特征的理解，进而采取更有效的防控措施，以减轻其对公共健康的影响。

然而，对于大多数普通医生来说，仅靠通过阅读胸腔 CT 图像难以识别患者器官是否处于异常状态，因此难以判断是否患有 COVID-19 及其炎症范围。因此，利用人工智能的相关技术来对 CT 扫描进行处理来进行对 COVID-19 的辅助诊断已然成为需要解决的问题。

近年来，随着人工智能技术的快速发展，CV 的医学影像领域也不断得到完善，DL 和 CNN 由于其强大的特征表示和提取能力在医学图像处理领域内被广泛运用。在医学图像领域中，分类和分割常常是被关注的重点问题，其中 CNNs 和 U-Net 仍是众多研究者广泛采用的底层架构。肺炎分割问题是一个医学图像处理领域中的一个细分问题，目的是从 X 光片或者是 CT 扫描中准确识别和分割出受肺炎感染的肺部区域。解决肺炎分割问题对于提早诊断和治疗肺炎非常重要，因为它有助于提高诊断的准确性，自动化的分割技术可以减少人为阅读误差；加快处理时间，自动化工具可以迅速处理大量图像；提供定量数据，自动分割可以提供更客观的测量结果，如病变大小和形状，这有助于监测疾病进展或回应治疗。

目前，肺炎分割面临的主要问题是语义分割的准确度较低，主要原因有以下几个方面：

- 1) 图像质量参差不齐：肺部 X 光或 CT 扫描的质量可能因多种因素而异，这可能影响到分割的准确性；
- 2) 模型泛化能力不足：即使模型在训练集上表现良好，但在实际应用中也可能

由于患者人群和影像获取条件的差异而难以在新的数据集上保持同样的准确度；

- 3) 病变表现具有多样性：肺炎在不同患者和不同阶段的表现可能有很大差异，包括不同形态和大小的病灶，这给算法识别具体模式带来了挑战；
- 4) 数据集的注释质量不一：标记数据的质量对训练结果影响巨大，如果标记不准确或不一致，会直接导致模型性能下降。肺炎感染区域与正常组织间界限模糊，尤其在肺炎早期，肺炎区域可能与正常肺组织在视觉上只有微小差异，导致算法难以区分。

因此，在解决肺炎分割问题时，主要目标包括区分正常和受感染的肺组织，准确识别因感染导致的模糊边界，并通过分割后的图像进行感兴趣区域（ROI）提取，以评估感染的严重程度。从而有助于提早诊断和治疗肺炎，提高诊断的准确性，同时利用自动化的分割技术减少人为阅读误差。

本文主要基于 U-Net，对本身不具有识别出肺炎感染区域的 U-Net 在其基础上进行一定程度的模型优化，优化后的 UResnet 能够在一定程度上准确识别出肺炎感染区域，但是仍存在一定的错误分类与预测，应在未来接着优化该模型。

2 相关工作

近年来，COVID-19 和其他肺炎的 CT 图像分割与诊断取得了显著进展。许多研究通过结合深度学习方法和创新的数据预处理技术，提出了独特的框架和网络架构来实现这一目标。例如，Faeze Gholamiankhah 和 Samaneh Mostafapour 使用残差网络从 CT 图像中分割正常和 COVID-19 患者的肺部，通过半自动和手动生成肺部掩膜，实现了对感染区域的精确识别，确保了分割的准确性^[1]。Guotai Wang 和 Xinglong Liu 提出的 COPLE-Net 通过抗噪声框架和自适应自集成策略解决了数据标签噪声问题，显著提高了 COVID-19 病灶分割性能，同时利用抗噪声 Dice 损失函数维护了前景与背景之间的平衡，确保病灶分割的精准性^[2]。Amine Amyar 和 Romain Modzelewski 设计的多任务深度学习模型结合了分割、分类和重建任务，充分利用任务间的关联性增强模型的识别性能，在 CT 图像分割中取得了超过 0.88 的 Dice 系数和 97% 以上的 ROC 曲线下面积^[3]。Qianfei Zhao 和 Huan Wang 开发的 LCOV-Net 通过轻量级注意力卷积块（LACB）实现了对

3D CT 图像中 COVID-19 病变区域的精准分割，显著降低了计算成本，同时保持了高鲁棒性^[4]。

为了进一步提升 CT 图像分析的性能，研究者结合多种评估指标全面衡量模型性能，包括 Dice 系数、交并比 (IoU)、准确度和召回率等。Romanov 和 Bach 的基于深度学习的诊断系统通过引入对比度限制自适应直方图均衡化 (CLAHE) 来改善图像质量，并利用 U-Net 架构对肺部进行分割，有效增强了 COVID-19 感染和肺炎筛查的准确度^[5]。Chen Zhao 和 Yan Xu 利用 3D V-Net 和形状变形模块从 CT 图像中提取肺实质的纹理特征，辅助 COVID-19 的诊断与分割^[6]。Mahmoudi 和 Benameur 的 CNN 架构通过三层网络 and 全连接层的组合，能够快速且精确地对感染区域进行分割，结合四折交叉验证等技术确保了模型性能的稳定性，为 COVID-19 的检测和筛查提供了有效的工具^[7]。

此外，研究者通过数据增强、标准化和半监督学习策略确保了模型的泛化能力。Xiaoyan Wang 和 Yiwen Yuan 提出的 SSA-Net 模型利用空间自注意力机制和半监督学习策略，克服了标注数据不足的挑战，提高了 COVID-19 感染区域的识别精度^[8]。Shilpa Gite 和 Abhinav Mishra 通过 U-Net++ 模型对 CT 图像进行精准分割，评估肺结核的病变程度，并进行数据增强以提高检测准确性^[9]。通过这些技术创新，模型对肺炎和 COVID-19 的分割与诊断能力得到了显著提升，推动了医学图像分析领域的发展，为临床诊断和治疗提供了更有效的工具。

3 相关基础知识

3.1 用于肺炎分割的深度学习模型

深度神经网络 (Deep Neural Network, DNN)，作为人工神经网络的拓展，是一种模拟人脑处理复杂数据机制的计算模型。如图 3-1 所示，该模型由多层节点 (亦称为神经元) 构成，每一层均能从其前一层接收输入，并输出至下一层。此种层级结构赋予了 DNN 学习数据多层次特征表示的能力。每个神经元的输出均通过激活函数进行转换，这有助于网络捕捉非线性关系。常见的激活函数有 ReLU、Sigmoid 和 Tanh 等。DNN 通常包含输入层、隐藏层和输出层，每一层网络均可视为一个特征转换器，将输入数据转化为更高层次的抽象表示。各层之间以全连接形式连接，数据自输入层流经隐藏层，最终到达输出层。在训练阶段，

DNN 通过反向传播算法和梯度下降优化方法对网络权重进行调整，旨在最小化预测结果与真实值之间的差异。而在推理阶段则根据训练得到的权重和激活函数，对新输入的数据进行特征提取和分类或回归预测。




图 3-1 深度神经网络架构

不同于传统的深度神经网络，卷积神经网络（Convolution Neural Network, CNN）具有稀疏连接、权值共享、平移等变等特点。如图 3-2 所示，CNN 通常由一个或多个卷积层、池化层和全连接层组成。卷积层负责提取输入的肺部 CT 图像数据的局部特征，它通过滤波器（或称为卷积核）在输入数据上滑动计算得出特征图，实现特征的自动提取与学习，在这个过程中，权值共享机制则有助于减少模型的参数数量，提高训练效率。提取得到的特征向量通过池化层（通常为最大池化或平均池化）可以降低特征维度，从而提取出 CT 图像数据的高语义深度特征，并减少计算量，提高肺部 CT 识别肺炎感染区域的效率。经过连续的卷积和池化操作，高层的网络结构能够从原始输入中提取越来越抽象的特征。最终，通过全连接层将提取的高级特征映射到输出空间，完成肺炎分割任务的预测。不过随着网络层数的增加，CNN 会出现梯度消失或者梯度爆炸的现象，此时可以考虑引入残差网络以解决梯度消失的问题。

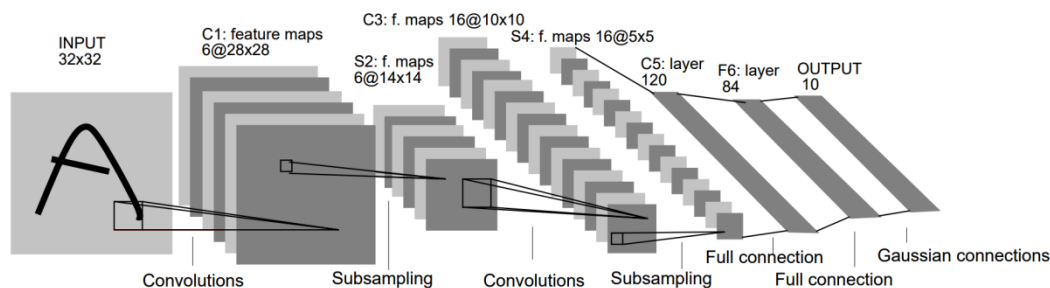


图 3-2 卷积神经网络架构

U-Net 架构是为图像分割特别设计的深度学习模型，广泛应用于医学图像处

理，在医学图像的精确分割中表现出色。该模型的核心是由收缩路径和扩张路径组成，有效地捕获上下文信息并精确定位。U-Net 通过强化数据扩增，例如旋转、平移和缩放，来增强对小数据集的学习能力和模型的泛化性。此外，它采用滑动窗口技术处理大图像，将大图像切割成小块（patches），单独预测后再将它们重组，这种方法提高了处理效率，同时保持了图像分割的高质量。在扩张路径中，U-Net 使用转置卷积代替简单上采样，保留了图像的细节和边缘信息，且可以精确定位图像中的对象边界。此外，每个卷积层后通常跟随一个批量归一化层，以加速训练并提高模型的稳定性。其独特的跳跃连接设计则有助于在更深层次上保留更多的原始图像信息，从而提高特征的传递效率和分割的准确性。总体而言，U-Net 的结构和策略的独创性在多个医学图像处理任务中展现了其作为该领域内标杆模型的地位。

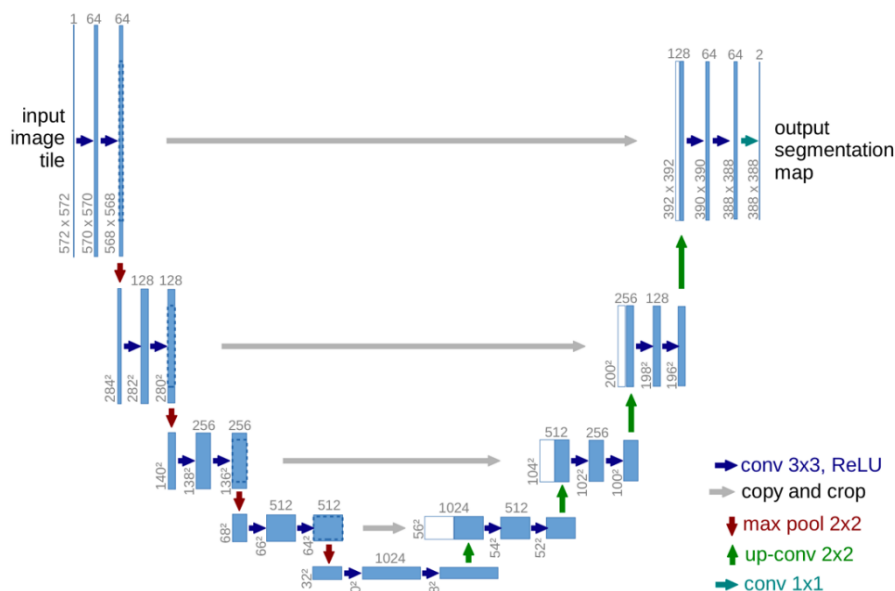


图 3-3 U-Net 网络架构

3.2 肺炎分割的评价标准

肺炎分割作为一个医学图像分割问题，可以使用混淆矩阵（Confusion Matrix）来评估模型的性能。混淆矩阵是一个 2×2 的矩阵，其中的两个类别分别代表肺炎病变和正常组织。混淆矩阵反映了模型的分割结果与实际情况的对应关系，每一行代表像素的真实类别，每一列代表模型预测的类别，矩阵中的元素 C_{ij} 表示真实类别 T_i 被模型识别为 T_j 的次数。

在评估模型对肺炎病变的分割能力时，将病变区域视为正例（Positive, P），

将其他区域视为负例 (Negative, N)。在一般的肺炎分割的上下文中，混淆矩阵可以包括以下四种情况：

1. 真正例 (True Positive, TP)：模型正确地将正例预测为正例，即模型准确地识别出了病变区域，这主要体现在混淆矩阵的主对角线上的 class2 和 class3 部分。

2. 假正例 (False Positive, FP)：模型错误地将负例预测为正例，例如模型将正常区域误识别为病变区域。

3. 真负例 (True Negative, TN)：模型正确地将负例预测为负例，即模型正确地识别出正常区域，不认为其是病变区域。

4. 假负例 (False Negative, FN)：模型错误地将正例预测为负例，即模型未能识别出实际存在的病变区域，将其归类为正常区域。

下图 3-4 展示了在当分类模型标签数为 4 时，评估模型对于肺炎的识别能力的混淆矩阵，以及对应的情况示意，图中数值含义表示模型将某个实际标签分类为某个预测标签的百分比。




图 3-4 混淆矩阵示例

基于混淆矩阵，可以计算出模型表现的评估指标 (Evaluation Metrics)，常见的评估指标有精确率、精度、召回率以及 F1 值。其含义与计算方式如下：

1. 准确率 (Accuracy)：指模型的整体正确率，即对于给定的测试手势数据集，模型正确预测正例和负例的数量占总样本数的比例。其计算公式如公式(3.1)所示：

$$\text{Accuracy} = \frac{TP + TN}{TP + FP + TN + FN} \quad (3.1)$$

2. 精度 (Precision): 模型精度针对预测结果的指标, 表示手语动作被正确地预测为正例的种类占所有被预测为正例的种类数的比例。精度的计算公式如公式(3.2)所示:

$$\text{Precision} = \frac{TP}{FP + TP} \quad (3.2)$$

3. 召回率 (Recall): 召回率针对原始实例的指标, 表示手语动作被正确地预测为正例的种类占真实值为正例的实例数的比例。召回率的计算公式如公式(3.3)所示:

$$\text{Recall} = \frac{TP}{FN + TP} \quad (3.3)$$

4. F1 值: F1 值综合考虑了精度和召回率, 它是两者的调和平均数, 其计算公式如公式(3.4)所示:

$$F1 = \frac{2 \times P \times R}{P + R} \quad (3.4)$$

其中 P 表示精度, R 表示召回率。

我们引入作为图像分割问题的重要评价指标交互比 (IoU) 以及 DICE。其含义与计算方式如下:

1. 交互比 (IoU): IoU 衡量两个区域之间的交集与并集的比率。通常用于图像分割, 计算预测区域与真实区域的重叠程度, 其计算公式如公式(3.5)所示:

$$\text{IoU} = \frac{|A \cap B|}{|A \cup B|} \quad (3.5)$$

其中 A 通常表示模型预测出的分割区域, B 通常表示实际的分割区域或标签区域。

2. DICE: DICE 系数是用于衡量两个集合之间相似度的统计指标。它常用于图像分割任务中评估预测分割区域与真实分割区域之间的重叠程度, 其计算公式如公式(3.6)所示:

$$\text{DICE} = \frac{2 \times |A \cap B|}{|A| + |B|} \quad (3.6)$$

4 模型优化

4.1 ResNet

ResNet 通过引入残差连接解决了深层神经网络中梯度消失或梯度爆炸的问题。残差连接允许信息直接通过网络层进行传播，从而使得网络可以训练更深的结构。

本项目选取使用 ResNet34，其残差结构如下图所示：




图 4-1 ResNet34 残差结构

其参数个数： $3 \times 3 \times 64 \times 64 + 3 \times 3 \times 64 \times 64$ 。

4.2 Swin Transformer

由于原有的 U-Net 模型经过实验后发现无法检测出 class2 和 class3 即磨玻璃影和实变区域，因此希望引入注意力机制来增加小目标检测的功能。故本文在 U-Net 的基础上添加 Swin Transformer 模块。

Swin Transformer 采用 shifted window 移动窗口的方法，其解决了若以像素点为单位的 ViT，其序列过长问题；可以通过窗口交互的方法来变相实现全局的 transformer；减小了计算复杂度，其复杂度随图片大小而线性增长，而不是像传统的 ViT 为平方级增长。对于本项目来说，有效规避了 transformer 对于大尺寸图像的计算问题与其数据量需求巨大的问题。

4.2.1 Swin Transformer 与 ViT 的区别

1) 采样方式

Swin Transformer 开始采用 4 倍下采样的方式，后续采用 8 倍下采样，最终采用 16 倍下采样；而 ViT 则一开始就使用 16 倍下采样。

2) 目标检测机制

Swin Transformer 中，通过 4 倍、8 倍、16 倍下采样的结果分别作为目标检测所用数据，可以使网络以不同感受野训练目标检测任务，实现对大目标、小目标的检测；而 ViT 则只使用 16 倍下采样，只有单一分辨率特征。

因此，Swin Transformer 更适合于数据量小且需要小目标检测的情况。

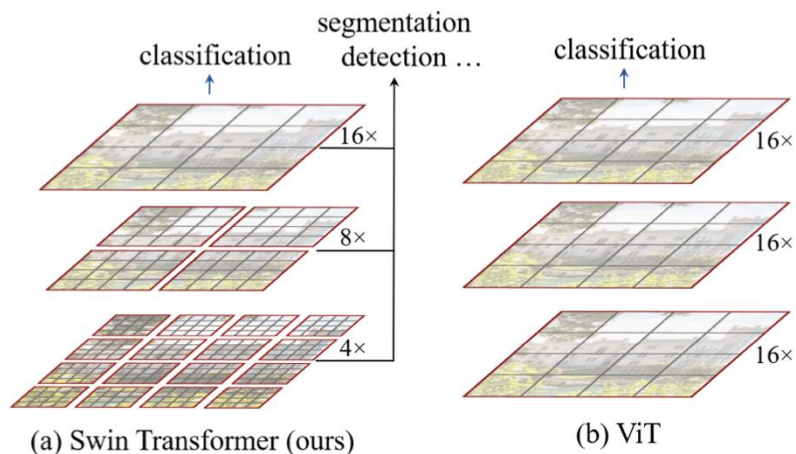


图 4-2 Swin Transformer 与 ViT 的对比结构

4.2.2 Swin Transformer 的网络结构

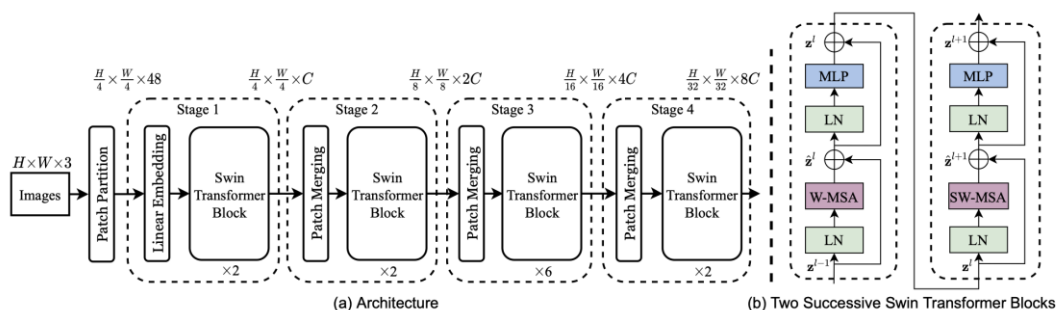


图 4-3 Swin Transformer 网络结构图

其中，图(a)表示 Swin Transformer 的网络结构流程，图(b)表示两阶段的 Swin Transformer Block 结构。值得注意的是，在 Swin Transformer 中，每个阶段的 Swin Transformer Block 结构都是 2 的倍数，因为里面使用的都是两阶段的 Swin Transformer Block 结构。

以下是 Swin-Transformer 的基础流程：

- 1) 输入一张图片 $[H * W * 3] [H * W * 3] [H * W * 3]$;
- 2) 图片经过 Patch Partition 层进行图片分割;
- 3) 分割后的数据经过 Linear Embedding 层进行特征映射;

- 4) 将特征映射后的数据输入具有改进的自关注计算的 Transformer 块(Swin Transformer 块), 并与 Linear Embedding 一起被称为第 1 阶段;
- 5) 与阶段 1 不同, 阶段 2-4 在输入模型前需要进行 Patch Merging 进行下采样, 产生分层表示;
- 6) 最终将经过阶段 4 的数据经过输出模块 (包括一个 Layer Norm 层、一个 Adaptive AvgPool 层和一个全连接层) 进行分类。

4.2.3 SW-MSA

由于 W-MSA 只能关注窗口本身的内容, 而不允许跨窗口连接, 窗口与窗口之间是无法进行信息传递的。而 SW-MSA 通过移动窗口的方式, 引入跨窗口连接的同时保持非重叠窗口的高效计算。如下图左所示为第 1 层使用 W-MSA 的方式, 而在下一层 l+1 层必定为 SW-MSA 的方式 (如右图所示), 两者合在一起作为一个 2 阶段的 Swin Transformer Block 模块。




图 4-4 Swin Transformer 中计算自注意力的滑动窗口方法

4.3 网络结构




图 4-5 UResnet 网络结构图

项目组通过引入 Swin Transformer 与 Resnet 模块，解决了原始 U-Net 模型在处理识别肺炎感染区域这种小目标时效果欠佳的问题，能够增强模型对小目标的检测能力。

通过在编码器部分引入 ResNet 模块，用于特征提取以更好地捕捉图像的细节特征，并通过残差连接解决深层网络中的梯度消失问题。

U-Net 的局部卷积操作虽然有效，但在捕捉全局特征时存在局限。Swin Transformer 模块通过局部窗口和移位窗口策略，实现了全局信息的高效交互，有助于提升模型在复杂图像中的表现。此外，传统的全局自注意力机制在处理大尺寸图像时计算复杂度高。Swin Transformer 通过局部窗口的自注意力机制和移位窗口策略，降低了计算复杂度，使得模型在处理大尺寸图像时更加高效。

5 实验分析

本实验主要基于使用基于 U-Net 而改进的 UResnet 对肺部 CT 图进行肺炎识别的图像分割问题。下表是后文实验中所涉及的实验指标的符号与含义：

符号	含义
Epoch	数据集的完整遍历次数
Batch Size	每次迭代训练的样本数量
Train_Loss	模型在训练集上的预测误差
Train_Accuracy	模型在训练集上的准确率
Dice	衡量模型在验证集上的分割性能
IoU_Score	衡量预测分割与真实分割之间的交集与并集的比率
Precision	模型预测的正例中实际为真的比例
Recall	模型能够识别实际正例的比例
F1	衡量预测结果和真实结果之间的重叠程度

5.1 数据集

本实验数据集来自中国胸部 CT 图像调查联盟 (CC-CII) 的 CT 切片图像的病变分割数据集。150 名新冠肺炎患者的总共 750 个 CT 切片被手动地分割成背景、肺区、磨玻璃影 (GGO) 和实变 (CL)。

5.2 DICE




图 5-1 不同网络下肺炎分割结果的 DICE 分数

5.2.1 U-Net 与 UResnet 的训练比较

1) U-Net:

在训练初期, U-Net 的 DICE 分数较低, 约为 0.35。这表明初始模型在处理新冠肺炎 (Covid-19) 肺炎分割任务时, 存在显著的性能不足。随着训练轮次的增加, U-Net 的 DICE 分数逐渐提升, 最终在第 16 轮次达到约 0.55, 尽管 DICE 分数有所提升, 但相比 UResnet 仍有差距。

2) UResnet:

UResnet 在训练初期即表现出较高的 DICE 分数, 约为 0.60。这表明优化后的模型在初始阶段就能够更准确地进行肺炎区域分割。在第 2 轮次之后, DICE 分数迅速稳定在 0.65 到 0.70 之间。这显示出优化模型的高效性和稳定性, 能够在较少的训练轮次中达到高性能。在第 16 轮次时, DICE 分数仍保持在 0.65 到 0.70 之间, 明显优于 U-Net。

5.2.2 UResnet 优化带来的具体改进

优化后的 UResnet 在前几轮次中迅速达到并保持高水平的 DICE 分数, 表明其收敛速度更快, 能够在更短的时间内达到较高的性能, 且 UResnet 的 DICE

分数显著高于 U-Net，特别是在训练的早期阶段和最终性能上，这表明优化后的模型在肺炎分割任务中具有更高的精度；此外，UResnet 的 DICE 分数在训练过程中波动较小，表现出更好的稳定性，减少了训练过程中可能出现的过拟合或欠拟合问题。

5.3 F1

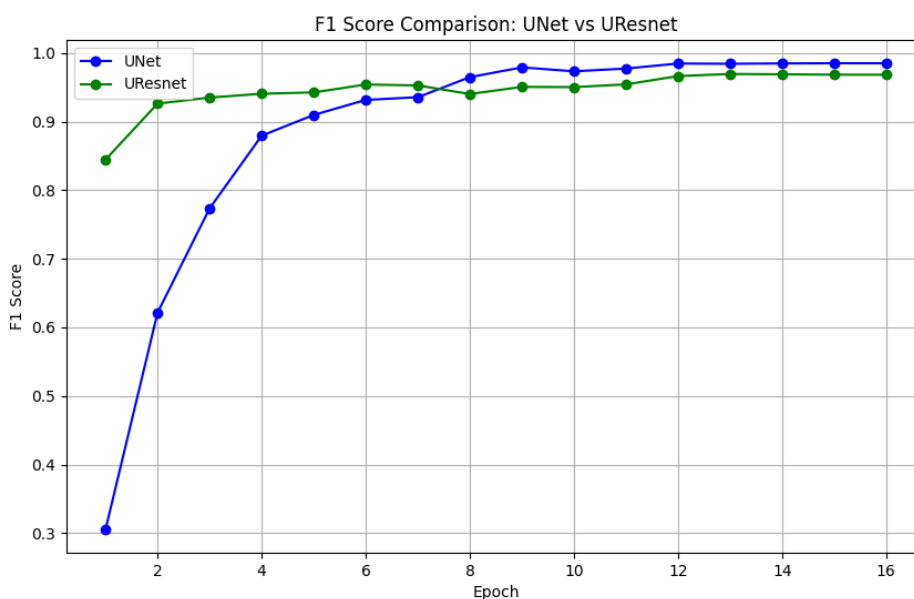


图 5-2 不同网络下肺炎分割结果的 F1 分数

5.3.1 U-Net 与 UResnet 的训练比较

1) U-Net:

在训练初期，U-Net 的 F1 分数较低，约为 0.3。这表明初始模型在处理新冠肺炎（Covid-19）肺炎分割任务时，存在显著的性能不足。随着训练轮次的增加，U-Net 的 F1 分数逐渐提升，最终在第 6 轮次达到 0.9，并在第 16 轮次接近 0.95，虽然 F1 分数有明显提升，但相较于 UResnet，仍有差距。

2) UResnet:

UResnet 在训练初期即表现出较高的 F1 分数，约为 0.85。这表明优化后的模型在初始阶段就能够更准确地进行肺炎区域分割。在第 2 轮次后，F1 分数迅速稳定在 0.9 到 1.0 之间。这显示出优化模型的高效性和稳定性，能够在较少的训练轮次中达到高性能。在第 16 轮次时，F1 分数保持在 0.9 到 1.0 之间，

明显优于 U-Net。

5.3.2 UResnet 优化带来的具体改进

优化后的 UResnet 在前几轮次中迅速达到并保持高水平的 F1 分数，表明其收敛速度更快，能够在更短的时间内达到较高的性能。虽然两者最终都趋于稳定，但是 U-Net 的 F1 分数略高于 UResnet。

5.4 IOU

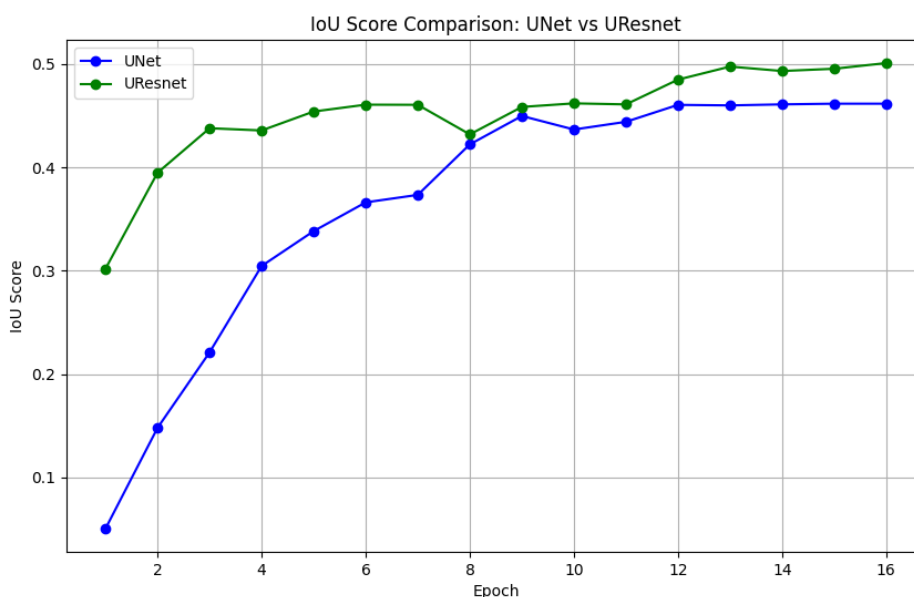


图 5-3 不同配置下肺炎分割结果的 IOU 曲线

5.4.1 U-Net 与 UResnet 的训练比较

1) U-Net:

在训练初期，U-Net 的 IoU 分数较低，约为 0.1。这表明初始模型在处理新冠肺炎（Covid-19）肺炎分割任务时，存在显著的性能不足。随着训练轮次的增加，U-Net 的 IoU 分数逐渐提升，最终在第 8 轮次达到 0.4 并趋于稳定，尽管 IoU 分数有所提升，但相较于 UResnet，仍有差距。

2) UResnet:

UResnet 在训练初期即表现出较高的 IoU 分数，约为 0.3。这表明优化后的模型在初始阶段就能够更准确地进行肺炎区域分割。在第 4 轮次后，IoU 分数迅速稳定在 0.45 到 0.5 之间。这显示出优化模型的高效性和稳定性，能够在较少

的训练轮次中达到高性能。在第 16 轮次时, IoU 分数保持在 0.45 到 0.5 之间, 相对优于 U-Net。

5.4.2 UResnet 优化带来的具体改进

优化后的 UResnet 在前几轮次中迅速达到并保持高水平的 IoU 分数, 表明其收敛速度更快, 能够在更短的时间内达到较高的性能。且 UResnet 的 IoU 分数显著高于 U-Net, 特别是在训练的早期阶段和最终性能上, 这表明优化后的模型在肺炎分割任务中具有更高的精度; 此外, UResnet 的 IoU 分数在训练过程中波动较小, 表现出更好的稳定性, 减少了训练过程中可能出现的过拟合或欠拟合问题。

5.5 混淆矩阵

5.5.1 U-Net 与 UResnet 的训练比较

实验结果的混淆矩阵中，行表示预测类别，列表示实际类别。对角线上的元素代表正确的分类结果，而对角线以外的元素则表示误分类的结果。其中 class0 代表背景、class1 代表肺区、class2 代表磨玻璃影(GGO)和 class3 代表实变(CL)，其中 class2 和 class3 能体现出肺炎感染区域。

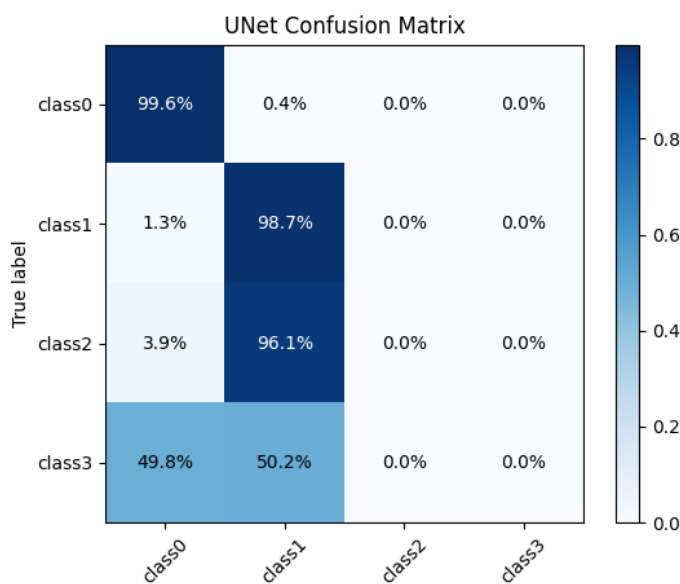


图 5-5 U-Net 模型下的混淆矩阵

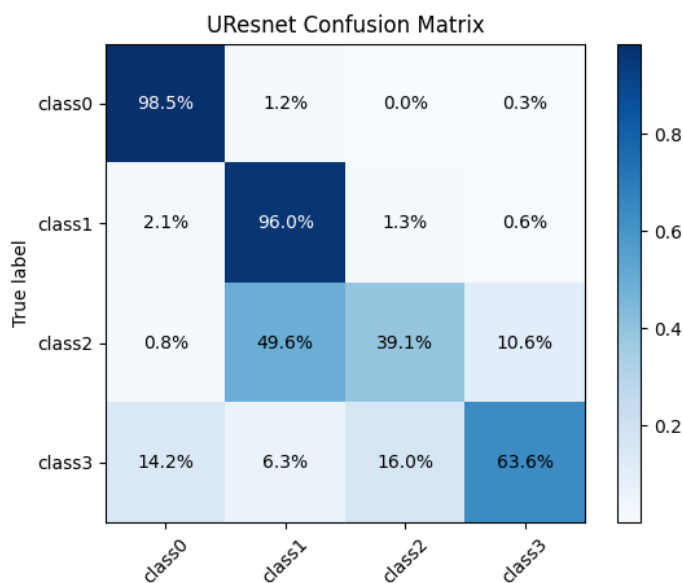


图 5-6 UResnet 模型下的混淆矩阵

从图 5-5 与图 5-6 中我们可以得知，U-Net 和 UResnet 在 class0 和 class1 的分类准确度均较高，但是 U-Net 对于 class2 和 class3 的分类准确度为 0，UResnet 在 class2 中的分类准确为 39.1%，其中 49.6% 被误分类为 class1，在 class3 中的分类准确为 63.6%。

5.5.2 UResnet 优化带来的具体改进

优化后的 UResnet 在 class2 和 class3 上的分类准确度显著提升，表明其在处理这些复杂类别时更加有效。尽管 UResnet 在 class2 上的误分类率较高，但相比 U-Net，UResnet 的整体误分类率有所降低，特别是在 class3 上的表现更加稳定。

5.5.3 混淆矩阵小结

U-Net 和 UResnet 都能很好的识别出背景与肺区，但是 U-Net 并未准确识别出实际体现肺炎感染区域即磨玻璃影和实变区域。虽然 UResnet 在磨玻璃影的检测中误分类率较高，但明显优于不能检测出该类的 U-Net，且 UResnet 在实变的识别中表现相对较好且稳定。这表明经过优化后 UResnet 能在一定程度上识别出肺炎感染的区域，虽然仍有一定的误诊率与漏诊率，在一定程度上能辅助医生进行诊疗判断，但如若需要落实到临床使用中该模型还需要不断优化与提升。

5.6 实验预测图




图 5-7 U-Net 模型下的预测结果图




图 5-8 UResnet 模型下的预测结果图

从图 5-7 与图 5-8 中我们可以得知，U-Net 和 UResnet 对于背景和肺区的预测准确度较高，但是 U-Net 并不能识别出肺炎区域。然而观察 UResnet 的预测图，我们可以发现尽管 UResnet 能正确识别出一定的磨玻璃影与实变区域，但仍然有一定的误识别与漏识别区域，且在膈肌（左肺空洞）与肺部边缘处有一定的错误分类预测的附着。这仍需要我们在未来对模型进行优化。

6 图像处理系统

图像处理系统基础运行环境为 Python 3.9 和 Pytorch 1.13.1，使用 Opencv 对图像进行基础处理，PyQt5 进行 GUI 开发。

如图所示，在导入图片后可以对图片进行基础变换，如图像增强、边缘检测等等。传入待检测的肺部 CT 图像后可以进行肺炎图像处理，会提供结果和详细解释。

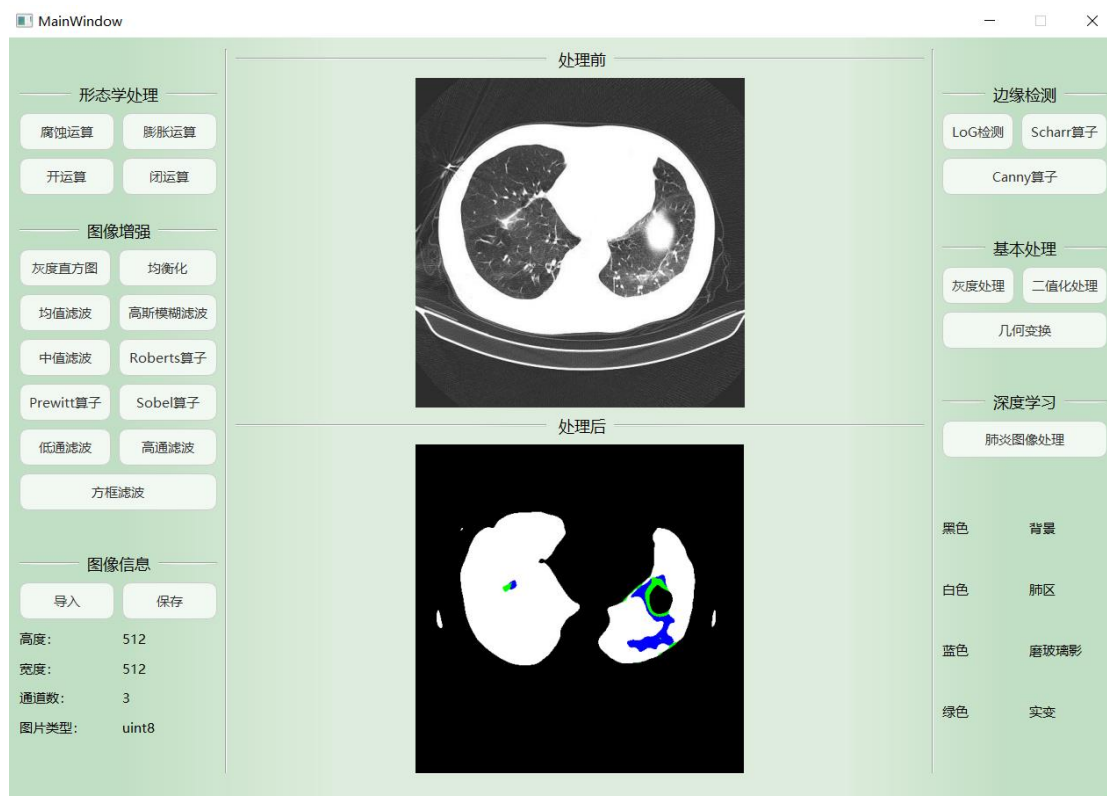


图 6-1 图像处理系统

参考文献

- [1] Gholamiankhah F , Mostafapour S , Goushbolagh N A ,et al.Automated lung segmentation from CT images of normal and COVID-19 pneumonia patients[J]. 2021.DOI:10.48550/arXiv.2104.02042.
- [2] Wang G , Liu X , Li C ,et al.A Noise-robust Framework for Automatic Segmentation of COVID-19 Pneumonia Lesions from CT Images[J].IEEE Transactions on Medical Imaging, 2020, PP(99):1-1.DOI:10.1109/TMI.2020.3000314.
- [3] Amyar A, Modzelewski R, Li H, Ruan S. Multi-task deep learning based CT imaging analysis for COVID-19 pneumonia: Classification and segmentation[J]. Computers in Biology and Medicine, 2020, 126: 104037. DOI:10.1016/j.combiomed.2020.104037.
- [4] Zhao Q , Wang H , Wang G .LCOV-NET: A Lightweight Neural Network For COVID-19 Pneumonia Lesion Segmentation From 3D CT Images[C]//2021 IEEE 18th International Symposium on Biomedical Imaging (ISBI).IEEE, 2021.DOI:10.1109/ISBI48211.2021.9434023.
- [5] Sauter A W .Automated CT Lung Density Analysis of Viral Pneumonia and Healthy Lungs Using Deep Learning-Based Segmentation, Histograms and HU Thresholds[J].Diagnostics (Basel, Switzerland), 11(5):738[2024-06-28].DOI:10.3390/diagnostics11050738.
- [6] Zhao C , Xu Y , He Z ,et al.Lung Segmentation and Automatic Detection of COVID-19 Using Radiomic Features from Chest CT Images[J].Pattern Recognition, 2021, 119(10223):108071.DOI:10.1016/j.patcog.2021.108071.
- [7] Mahmoudi, R.; Benameur, N.; Mabrouk, R.; Mohammed, M.A.; Garcia-Zapirain, B.; Bedoui, M.H. "A Deep Learning-Based Diagnosis System for COVID-19 Detection and Pneumonia Screening Using CT Imaging." Appl. Sci. 2022, 12, 4825. DOI: 0.3390/app12104825.

- [8] Wang X , Yuan Y , Guo D ,et al.SSA-Net: Spatial self-attention network for COVID-19 pneumonia infection segmentation with semi-supervised few-shot learning[J].Medical image analysis, 2022:79.
- [9] Gite S , Mishra A , Kotecha K .Enhanced lung image segmentation using deep learning[J].Neural Computing and Applications, 2022.DOI:10.1007/s00521-021-06719-8.