

MDA-Net: 用于视网膜血管分割的多维注意力网络

李绍丽, 梁铁林

沈阳工业大学, 信息科学与工程学院, 仪器科学与技术, 辽宁省 沈阳市

发布日期: 2025年4月28日

摘要

眼底图像在诊断和治疗眼科疾病(例如高血压、动脉硬化和糖尿病视网膜病变等)中发挥重要作用,其视网膜血管形态信息可作为这些疾病诊断的重要指标,因此对视网膜血管精准分割非常重要。随着计算机技术的不断发展,深度学习方法为医学影像分割提供了新的思路。由于视网膜血管结构复杂、尺度不一,现有的U-Net模型在应对这些任务时,仍然面临显著挑战。对这些问题,我们提出了一种基于多维注意力机制的视网膜血管分割网络MDA-Net。该方法基于UNet结构,通过减少编码器-解码器层数至3层优化网络设计,并引入坐标分组特征融合模块(Coordinate Grouped Feature Fusion, CGFF)、多维特征增强模块(Multi-Dimensional Feature Enhancement, MDFF)。首先,CGFF模块通过分组卷积和多维池化融合多尺度特征,提升了模型对血管分布不均的适应性。其次,MDFF模块结合通道洗牌、多维注意力和池化操作,增强了微小血管特征的提取能力,尤其在低对比度和复杂背景下的表现更为鲁棒。实验结果表明,该方法在DRIVE、STARE数据集上的准确性(ACCURACY,ACC)分别达到0.9825、0.9842,敏感性(SENSIBILITY,SE)分别达到0.8211、0.8342,特异性(SPECIFICITY,SP)分别达到0.9840、0.9872。本文提出的MDA-Net为改善视网膜血管分割性能提供了新的思路 and 方案。

关键词

特征增强; 特征融合; UNet; 注意力机制

MDA-Net: Multi-Dimensional Attention Network for Retinal Vessel Segmentation

Shaoli Li, Tielin Liang

School of Information Science and Engineering, Instrument Science and Technology, Shenyang University of Technology, Shenyang 110870, China

Abstract

Fundus images play an important role in the diagnosis and treatment of ophthalmic diseases (such as hypertension, arteriosclerosis and diabetic retinopathy), and the morphological information of retinal blood vessels can be used as an important index for the diagnosis of these diseases, so it is

文章引用: 李绍丽, & 梁铁林. (2025). MDA-Net: 用于视网膜血管分割的多维注意力网络[J]. 计算机科学辑要, 1(1), 86-95.
ISSN Print: 3079-5362; ISSN Online: 3079-5370.
DOI: 10.63313/CS.8007

very important for accurate segmentation of retinal blood vessels. With the continuous development of computer technology, deep learning method provides a new idea for medical image segmentation. Due to the complex structure and different scales of retinal blood vessels, the existing U-Net model still faces significant challenges in dealing with these tasks. To solve these problems, we propose a retinal vascular segmentation network MDA-Net based on multidimensional attention mechanism. Based on the U-Net structure, this method optimizes the network design by reducing the number of encoder-decoder layers to three layers, and introduces the Coordinate Grouped Feature Fusion (CGFF), multi-dimensional feature enhancement (MDFE) and multi-scale convolution enhancement (MSCE). Firstly, CGFF module integrates multi-scale features by grouping convolution and multi-dimensional pooling, which improves the adaptability of the model to uneven distribution of blood vessels. Secondly, MDFE module combines channel shuffling, multi-dimensional attention and pooling operation to enhance the extraction ability of micro-vessel features, especially in low contrast and complex background. Experimental results show that the accuracy (ACC), sensitivity (SE) and specificity (SP) of this method DRIVE 0.9825, 0.9842 and 0.9895, 0.8211, 0.8342 and 0.8452 respectively, and 0.9840, 0.9872 and 0.992 respectively. MDA-Net proposed in this paper provides a new idea and scheme for improving the performance of retinal blood vessel segmentation.

Keywords

Feature Enhancement; Feature Fusion; UNet; Attention Mechanism

Copyright © 2025 by author(s) and Erytis Publishing Limited.

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

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



1. 引言

在临床医学中, 视网膜和脉络膜血管疾病, 如老年性黄斑变性(AMD)、糖尿病性视网膜病变(DR)和视网膜静脉闭塞(RVO), 对患者的视力健康构成了严重威胁[1]。全球范围内, AMD 和 DR 是导致老年人视力丧失的主要原因, 影响数百万患者[2]。这些疾病通常导致视网膜血管结构发生显著变化, 观察这些变化不仅可以帮助医生进行早期诊断, 还能用于病情监测和治疗效果的评估[3]。例如, 脉络膜新生血管(CNV)的形成是 AMD 发展的关键病理机制, 常导致严重的视力损害[4]; 而高血糖状态下, 视网膜微血管的闭塞会引发局部视网膜缺血, 并进一步促使新生血管生成[5]。这些病变可能导致视网膜穿孔, 最终不可逆地损害视力[6]。然而, 视网膜血管的复杂结构及其不对称性, 使得精确分割成为一项具有挑战性的任务[7]。视网膜中的血管呈现出多样的形态, 部分微小血管由于信号微弱[8]。现有的分割方法在应对这些挑战时取得了一定进展, 仍存在准确度不足的问题, 难以在实际临床应用中广泛推广[7]。此外, 毛细血管等不同类型的血管存在显著差异, 这进一步要求分割算法具备极高的泛化能力, 以准确区分这些血管结构[8]。因此, 本文工作的主要贡献如下: 针对视网膜血管分割任务中的血管边缘模糊, 我们提出一种基于多维注意力机制的视网膜血管分割网络 MDA-Net。MDA-Net 核心部分包括以下关键模块:

(1) 坐标分组特征融合模块 (Coordinate Grouped Feature Fusion, CGFF): 通过多维特征融合机制, 提升血管分布不均情况下的分割性能。该模块将输入特征图按通道分组, 使用全局池化提取全局信息, 结合共享卷积层强化微小血管特征的敏感性, 并通过加权优化特征图, 突出重要血管区域。

(2) 多维特征增强模块 (Multi-Dimensional Feature Enhancement, MDFE): 引入通道洗牌操作和多尺度卷积, 通过全局池化生成通道权重, 提取空间特征, 有效增强微小血管特征的提取, 特别在低对比度

和噪声环境下表现更佳。

2. 相关工作

早期的视网膜血管分割方法主要依赖于传统的图像处理技术,如滤波、阈值分割和边缘检测。例如,Liu 和 Sun [9]提出了通过灰度强度和曲率确定血管中心的血管跟踪方法,尽管该方法在血管宽度的计算上具有较高精度,但由于依赖种子点,无法检测无种子点的血管。为提升分割效果,Roychowdhury 等人[10]结合形态学处理和高斯混合模型对像素进行分类,虽然改善了分割性能,但这些方法的手工设计特征在不同图像场景下的表现仍显不足。Khan [11]尝试通过改进的匹配 3D 滤波和专用线检测方法来平衡分割的敏感性和特异性,但其对复杂多变的视网膜图像的适应性依然有限,主要因为依赖手工设计特征。然而,视网膜血管的细长、复杂结构及其低对比度特性,使得这一任务更具挑战性。为应对这些挑战,Mou 等人[12]开发了 CS2-Net,通过在编码器-解码器框架中引入自注意力机制,增强了对曲线结构的特征学习。Arias 等人[13]提出了一种新型损失函数,通过精确计算像素到血管树的距离来改善分割效果,但在高噪声图像中其性能依然受限。

此外,Liskowski 等人[14]引入了针对视网膜图像的特定数据增强技巧,显著提高了模型的鲁棒性,但其泛化能力在其他应用场景中可能有限。Yuan 等人[15]设计的 AACLA-MLA-D-U-Net,在多尺度血管分割上表现出色,但高计算复杂度使其更适合计算资源丰富的环境。

综上所述,虽然已有方法在视网膜血管分割任务上取得了一定进展,但在细小血管的精细分割仍存在不足。为此,我们提出了 MDA-Net,以进一步提升视网膜血管图像的分割精度。

3. 方法

本章提出的基于多维度注意力机制的深度特征优化图像分割算法(以下简称 MDA-Net),是对经典的 U-Net 结构进行改进。MDA-Net 在传统的四层编码器-解码器架构的基础上,减少了层数,将编码器和解码器的层数由四层缩减至三层。

MDA-Net 的网络结构(如图 1 所示)分为左侧的编码器部分和右侧的解码器部分,主要由五个模块组成:下采样模块、上采样模块、坐标分组特征融合模块、多维特征增强模块。这些模块协同工作,针对血管结构复杂、低对比度噪声干扰和微小血管检测困难等问题,优化了特征提取与融合过程。坐标分组特征融合模块(CGFF)嵌入到 U-Net 前两层。CGFF 使用分组卷积和多维池化(包括高宽方向的平均池化、最大池化和共享卷积)融合不同尺度的特征。多维特征增强模块(MDFE)只嵌入到 U-Net 的第三层。通过结合通道洗牌、通道注意力和空间注意力机制,抑制无效特征的干扰。

通过上述设计,MDA-Net 在 3 层 U 型结构和 3 组跳跃连接的基础上,充分利用 CGFF 和 MDFE 的协同作用,解决多次池化操作造成的信息丢失问题,并提升了在复杂背景和低对比度环境下的分割性能。

3.1. MDA-Net 整体架构

MDA-Net 的四层编码器-解码器结构简化为三层,以减少信息丢失并保留更多特征。MD-Net 的网络结构包括四个模块:下采样模块、上采样模块、坐标分组特征融合模块(CGFF)、多维特征增强模块(MDFE)。下采样模块作为编码器的基础操作层,通过最大池化技术提取多层次的血管特征信息,使用的下采样技术为最大池化。上采样模块则在解码器中通过双线性插值技术逐步恢复特征图分辨率,重建血管细节。坐标分组特征融合模块(CGFF)嵌入编码器中,通过分组卷积和多维池化融合多尺度特征,用于提取血管特征,提升模型对血管分布不均的适应性。多维特征增强模块(MDFE)嵌入跳跃连接中,结合通道洗牌、通道注意力和空间注意力机制强调模型学习到的有效特征并抑制无效特征。




Figure 1. The overall framework of MD Net

图 1. MDA-Net 的整体框架

3.2.坐标分组特征融合模块

该模块首先对每一组特征图将以独立的方式进行处理, 这样可以帮助网络有效减少冗余计算, 并集中注意力于更为相关的特征。假设输入特征图为 $x \in R^{C \times H \times W}$, 其中 C 为通道数, H 和 W 分别为图像的高度和宽度。在这一过程中利用坐标编码函数 $f_{coord}(x, h, w)$ 我们可以将图像中的空间坐标 (h, w) 映射到特征图的特征通道中, 从而增强特征图的空间信息表达。为了更好地捕捉不同尺度下的血管特征, 使用了多个不同大小的卷积 $k_1, k_2, \dots, k_n$ 进行卷积计算。具体来说, Y_i 表示每个尺度下的卷积结果。通过这一多尺度卷积过程, 模型能够捕获血管的细节和全局信息, 有效提高对复杂血管形态的分割能力。在完成多尺度卷积处理后, CGFF 模块会对所有尺度的特征图进行融合。为此, 采用了加权策略, 其中每个特征图 Y_i 根据其重要性进行加权合并, 得到融合后的特征图 Y_{fuse} :

$$Y_{fuse} = \sum_{i=1}^n \alpha_i Y_i \quad (1)$$

这里的 α_i 是每个特征图的权重系数, 权重系数会在训练过程中自适应地调整。

$$Y_{final} = \sum_{i=1}^n \alpha_i(t) Y_i \quad (2)$$




Figure 2. Structure of Coordinate Grouped Feature Fusion Module

图 2. 坐标分组特征融合模块的结构

3.3.多维特征增强模块

在处理复杂视觉任务，如视网膜血管分割时，模型需要有效提取多维特征。为此，我们设计了多维特征增强模块（MDFE）。在 MDFE 中，通道注意力通过线性变换和 Sigmoid 激活函数加权特征图的通道，从而增强对重要通道的关注，特别是细小血管和复杂血管区域的识别。使用 Sigmoid 激活函数来生成每个通道的权重系数，并根据这些权重对每个通道进行加权处理。公式为：

$$X_{att} = X' \times \sigma(\text{ChannelAttention}(X')) \quad (3)$$

其中， σ 表示 Sigmoid 激活函数， X_{att} 是通过加权后的特征图，表示网络已经加强了对重要血管区域的关注。通道洗牌是 MDFE 模块的创新。通道洗牌通过打乱通道顺序，提升特征表达能力。

$$X_{shuffled} = \text{ChannelShuffle}(X_{att}) \quad (4)$$




Figure 3. Multi-dimensional feature enhanced structure

图 3. 多维特征增强的结构

4. 实验设置

4.1. 实验环境搭建与具体训练策略

本文实验环境基于 Ubuntu 22.04 操作系统, 实验设备为 NVIDIA GeForce RTX 4090 GPU, 深度学习框架为 PyTorch 2.3.0, CUDA 版本为 12.1, 编程语言为 Python 3.12。batch_size 设置为 16, 优化器采用 AdamW (初始学习率为 0.001, 权重衰减为 0.01)。模型训练共进行 100 个 epochs。

4.2. 数据集

为了评估网络的分割性能, 本文使用 DRIVE、STARE 和 CHASE_DB1 三个公开视网膜血管数据集与其他算法进行对比, 验证所提出算法的分割性能和泛化能力。

DRIVE: 包含 40 幅彩色视网膜图像, 分辨率为 584×565 像素, 配有专家手动标注的血管分割结果, 为训练和评估提供精确参考。




Figure 4. The first line is the original image, and the second line is the label

图 4. 第一行是原始图像, 第二行标签

4.3. 数据增强

常用的三个公开数据集通常只包含 20 到 40 张图像, 这种数据量对于深度学习模型的训练而言显然远远不足, 难以支持模型学习到鲁棒的特征表达。为了解决这一问题, 我们设计了一种数据增广策略, 具体通过设定一个 48×48 像素的裁剪窗口, 在每幅图像上以随机滑动的方式进行采样 (图 7)。通过这一方法, 我们从原始数据集中生成了约 15000 个图像块, 每个图像块均保留了对应的血管分割标签, 从而构成一个完整的训练样本。这一过程显著扩展了训练数据集的规模, 增强了数据的多样性, 有助于提升模型的泛化能力。需要特别强调的是, 数据增广处理仅应用于训练集, 以确保模型在训练过程中能够接触到多样化的样本分布, 而测试集的样本则保持原始状态, 未进行任何增广操作, 从而保证评估结果的公平性和可靠性。




Figure 5. (a) the cut label block, (b) the corresponding image block image

图 5. (a)表示裁剪的标签块, (b)表示对应的图像块像

4.4.评价指标

为了全面评估网络在视网膜血管分割任务中的性能,本文选择了如下所示的性能指标。准确度(ACC)定义为正确分类的样本占样本总数的比例。ACC 值越高代表分割效果越好, ACC 的计算如下:

$$ACC = \frac{TN + TP}{TN + TP + FN + FP} \quad (5)$$

特异性(SP)是指模型正确判定阴性样本的能力,预测真阴性样本为阴性样本的能力。SP 只考虑预测为负的样本中分类器的准确性。因此, SP 越高,分类器实现的准确度越高。SP 的公式为:

$$SP = \frac{TN}{FN + FP} \quad (6)$$

灵敏度(SE)是模型正确确定一个正例样本的能力,预测真正例为正例的能力。SE 是一种用于评估二元分类模型性能的度量,通常也称为召回。它通过以下公式计算:

$$SE = \frac{TP}{TP + FN} \quad (7)$$

5. 实验结果与分析

5.1.消融实验

在 DRIVE 数据集上(见表 1),基础网络的准确率(ACC)、灵敏度(SE)、特异性(SP)和 AUC 分别为 0.9637、0.7329、0.9835 和 0.99798。随着引入 CGFF 模块,灵敏度(SE)从 0.7329 提升至 0.8384,特异性(SP)从 0.9835 提升至 0.9875,准确率(ACC)从 0.9637 提升至 0.9655。可以看出,CGFF 模块在分割结果中带来了显著改善。在验证了 CGFF 模块的有效性之后,我们将 MDFE 模块引入基础网络。ACC 从 0.9637 提升至 0.9647, SE 从 0.7329 提升至 0.7349, SP 从 0.9835 提升至 0.9866。SARE 数据集上

(见表 2), CGFF 模块、MDFE 模块以及 MDA-Net 的消融实验结果与在 DRIVE 数据集上的表现相似。

Table1. The ablation results on the DRIVE dataset

表 1. DRIVE 数据集上的消融结果

Methods	ACC	SE	SP
Baseline (UNet)	0.9637	0.7329	0.9835
Baseline+CGFF	0.9643	0.7349	0.9866
Baseline+MDFE	0.9646	0.7337	0.9864
Baseline+CGFF+MDFE	0.9735	0.8210	0.9865

Table2. Experimental results of ablation on STARE dataset

表 2. STARE 数据集上消融实验结果

Methods	ACC	SE	SP
Baseline (UNet)	0.9712	0.7412	0.9830
Baseline+CGFF	0.9742	0.7564	0.9880
Baseline+MDFE	0.9746	0.7331	0.9885
Baseline+CGFF+MDFE	0.9742	0.8554	0.9860

图 6 展示了 DRIVE 和 STARE 数据集的热力图分析。图 4 展示了在 DRIVE 和 STARE 数据集上的热力图分析, 绿框区域标识了我们关注的微细血管区域。当未引入 CGFF 和 MDFE 时, 模型在捕捉细节信息方面表现不足 (图 4(a))。引入 CGFF 显著改善了细微血管的重建能力 (图 3.7(b))。当加入 MDFE 后, 细节信息进一步增强, 噪声干扰得到有效抑制 (图 3.7(c))。当两个模块同时引入时, 模型的微细血管捕捉能力达到最佳效果 (图 4(d))。




Figure6. The thermal maps of DRIVE and STARE ablation experiments

图 6. DRIVE 和 STARE 消融实验热力图

5.2.对比实验

本文在 DRIVE、STARE 进行了对比实验。在 DRIVE 数据集上(见表 3), MDA-Net 的 ACC 为 0.9825,

AUC 为 0.9893，相较于其他方法（如 TransU_Net 和 CS-ViG-UNet），虽然灵敏度稍低，但特异性较高，表明其具有较强的背景噪声抑制能力。在 STARE 数据集上（见表 4），MDA-Net 取得了 ACC 为 0.9842，SP 为 0.9872，表现出色。与其他方法相比，MDA-Net 尽管灵敏度略低于 TransUNet，但整体性能更均衡。

Table3. Comparison of Different Segmentation Methods on DRIVE Dataset
表 3. DRIVE 数据集上不同分割方法的比较

Methods	ACC	SE	SP
TransUNet[15]	0.9732	0.8235	0.9873
AttUNet[16]	0.9647	0.8258	0.9876
R2UNet[17]	0.9645	0.8232	0.9846
UNet++[18]	0.9739	0.8449	0.9805
CS-ViG-UNet[19]	0.9707	0.8134	0.9765
MDA-Net	0.9825	0.8211	0.9840

Table4. Comparison of different segmentation methods on the STARE dataset
表 4. STARE 数据集上不同分割方法的比较

Methods	ACC	SE	SP
TransUNet[15]	0.9766	0.8752	0.9855
AttUNet[16]	0.9740	0.8462	0.9811
R2UNet[17]	0.9725	0.8432	0.9836
UNet++[18]	0.9739	0.8449	0.9805
CS-ViG-UNet[19]	0.9707	0.8634	0.9865
MDA-Net	0.9842	0.8342	0.9872

在图 7 的第一行中，MDA-Net 能够准确分割出粗大血管的主干结构，同时对细小分支和末梢血管的捕捉更为完整，与原始图像的血管分布高度一致。图 7 的第二行（STARE 数据集）中，MDA-Net 依然能够有效抑制背景干扰，清晰还原复杂的血管网络结构。




Figure 7. The segmentation results of six segmentation methods on are as follows
图 7. 六种分割方法的分割结果

基金项目

本工作得到了辽宁省教育厅高等学校基础科研项目(LJ212410142048)的部分资助。

参考文献

- [1] Huang Z, Fang Y, Huang H, et al. Automatic Retinal Vessel Segmentation Based on an Improved U-Net Approach [J]. Scientific Programming, 2021, 55(34):3219.
- [2] Wild S, Roglic G, Green A, et al. Global prevalence of diabetes estimates for the year 2000 and projection for 2030 [J]. Diabetes care, 2004, 27(5): 1047-1053.
- [3] J. Dong, Y. Cong, G. Sun, D. Hou, Semantic-transferable weakly-supervised endoscopic lesions segmentation, in Proc IEEE Int Conf Comput Vision (2019), Seoul, Korea, pp. 10712-10721. [Online]. Available: https://openaccess.thecvf.com/content_ICCV_2019/papers/Dong_Semantic-Transferable_Weakly-Supervised_Endoscopic_Lesions_Segmentation_ICCV_2019_paper.pdf.
- [4] Edita, Dervisevic, Suzana, et al. Challenges In Early Glaucoma Detection [J]. Medical archives (Sarajevo, Bosnia and Herzegovina), 2016, 70(3): 7-203.
- [5] Bibiloni P, González-Hidalgo M, Massanet S. A real-time fuzzy morphological algorithm for retinal vessel segmentation[J]. Journal of Real-Time Image Processing, 2019, 16(6): 2337 - 2350.
- [6] Fraz M M, Barman S A, Remagnino P, Hoppe A, Basit A, Uyyanonvara B, Rudnicka A R, Owen C G. An approach to localize the retinal blood vessels using bit planes and centerline detection[J]. Computer Methods and Programs in Biomedicine, 2012, 108(2): 600 - 616.
- [7] Hassan G, El-Bendary N, Hassanien A E, Fahmy A, Abullah M. S, Snasel V. Retinal blood vessel segmentation approach based on mathematical morphology[J]. Procedia Computer Science, 2015, 65: 612 - 622.
- [8] Yin Y, Adel M, Bourennane S. Retinal vessel segmentation using a probabilistic tracking method[J]. Pattern Recognition, 2012, 45(4): 1235 - 1244. 67.
- [9] Nayeibifar B, Moghaddamh. A .A novel method for retinal vessel tracking using particle filters[J]. Computers in Biology and Medicine, 2013. DOI:10.1016/j.compbiomed.2013.01.016.
- [10] Zhao J, Yang J, Ai D, Song H, Jiang Y, Huang Y, Zhang L, Wang Y. Automatic retinal vessel segmentation using multi-scale superpixel chain tracking[J]. Digital Signal Processing, 2018, 81: 26 - 42.
- [11] Al-Rawi M, Qutaishat M, Arrar M. An improved matched filter for blood vessel detection of digital retinal images[J]. Computers in Biology and Medicine, 2007, 37(2): 262 - 267.
- [12] Wang Y, Ji G, Lin P, Trucco E. Retinal vessel segmentation using multiwavelet kernels and multiscale hierarchical decomposition[J]. Pattern Recognition, 2013, 46(8): 2117 - 2133.
- [13] Oliveira W S, Teixeira J V, Ren T I, Cavalcanti G D C, Sijbers J. Unsupervised retinal vessel segmentation using combined filters[J]. PLOS ONE, 2016, 11(2): e0149943.
- [14] Frangi A F, Niessen W J, Vincken K L, et al. Multiscale vessel enhancement filtering[C]//Medical Image Computing and Computer-Assisted Intervention—MICCAI' 98: First International Conference Cambridge, MA, USA, October 11 - 13, 1998 Proceedings 1. Springer Berlin Heidelberg, 1998: 130-137.
- [15] Chen J, Lu Y, Yu Q, Luo X, Adeli E, Wang Y, Lu L, Yuille A L and Zhou Y 2021 TransU-Net: Transformers make strong encoders for medical image segmentation (arXiv:2102.04306).
- [16] Oktay O, Schlemper J, Folgoc L L, Lee M, Heinrich M, Misawa K, Mori K, McDonagh S, Hammerla N Y and Kainz B 2018 Attention U-Net: Learning where to look for the pancreas (arXiv:1804.03999).
- [17] Alom M Z, Hasan M, Yakopcic C, Taha T M and Asari V K 2018 Recurrent residual convolutional neural network based on U-Net (R2UNet) for medical image segmentation (arXiv:1802.06955).
- [18] Zhou Z, Rahman Siddiquee, et al. UNet++: A nested UNet architecture for medical image segmentation[J]. Proc. Int. Workshop on Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support, 2018, 18(2): 3-11.
- [19] Zhang, Y., Mao, Q., Tian, Y., Wang, W., Ren, L., & Li, H. (2025). Dual-path information enhanced pyramid U-Net for COVID-19 lung infection segmentation. Engineering Applications of Artificial Intelligence, 142, 109977.