

ICS

CCS

CI

团体标准

T/CI XXX-2023

医疗图像智能分析及处理技术规范

Technical specification for intelligent analysis and processing of medical images

(征求意见稿)

2023-X-X 发布

2023-X-X 实施

中国国际科技促进会 发布

中国国际科技促进会（CIAPST）是 1988 年经中华人民共和国国务院科技领导小组批准而成立的全国性社会团体。制定团体标准、开展标准国际化和推动团体标准实施，是中国国际科技促进会的工作内容之一。任何团体和个人，均可提出制、修订中国国际科技促进会团体标准的建议并参与有关工作。

中国国际科技促进会标准按《中国国际科技促进会标准化管理办法》进行制定和管理。

中国国际科技促进会征求意见稿经向社会公开征求意见，并得到参加审定会议的 80% 以上的专家、成员的投票赞同，方可作为中国国际科技促进会标准予以发布。

在本标准实施过程中，如发现需要修改或补充之处，请将意见和有关资料寄给中国国际科技促进会标准化工作委员会，以便修订时参考。

任何团体和个人，均可对本标准征求意见稿提出意见和建议，牵头起草单位联系方式
zhang_mch@163.com

中国国际科技促进会

地址：北京市海淀区中关村东路 89 号恒兴大厦 13F

邮政编码：100190

电话：010-62652520 传真：010-62652520

网址：<http://www.ciapst.org>

目 次

前 言	III
引 言	IV
1 范围	1
2 规范性引用文件	1
3 术语和定义	1
3.1 图像分割 Image Segmentation	1
3.2 可视化技术 Visualization Technique	1
3.3 特征提取 Feature Extraction	1
3.4 特征融合 Feature Fusion	1
3.5 图像配准 Image Registration	2
4. 总体设计	2
4.1 基本原则	2
4.2 医疗图像智能分析及处理技术总体思路介绍	2
4.3 医疗图像预处理	3
4.4 医学图像可视化技术	6
4.5 医学图像特征提取	9
4.6 医学图像特征融合技术	11
4.7 疾病诊断及病势推演技术	14

前 言

本文件按 GB/T1.1-2020《标准化工作导则第1部分：标准化文件的结构和起草规则》起草。

请注意本文件的某些内容可能涉及专利。本文件的发布机构不承担识别这些专利的责任。

本文件由河南科技大学提出。

本文件由中国国际科技促进会归口。

本文件起草单位：河南科技大学、河南科技大学第一附属医院、河南群智信息技术有限公司、河南省洛阳正骨医院（河南省骨科医院）、广州市香雪制药股份有限公司、深圳市人民医院。

本文件主要起草人：张明川、王琳、吴庆涛、吴利娟、宁召惠、朱军龙、冀治航、张虹、康志英、刘莹莹、顾孟杰、张茉莉。

本文件为首次发布。

引 言

为了拓展医疗图像智能分析及处理的应用,以及进一步促进医疗图像数据的跨机构和跨平台共享,以支持协作研究和二次分析,同时为了顺应我国医学图像处理领域的不断发展需求,本文件制定了医疗图像智能分析及处理的规范。

本文件针对医疗图像的处理与分析,主要包括医疗图像预处理(医学图像分割、去噪、图像增强等)、特征提取(颜色、纹理、形状、空间关系等)、医学图像可视化(三维重建、图像融合、图像配准等)、疾病诊断及病势推演技术等。

由河南科技大学负责具体技术指标的解释工作。

征求意见稿

医疗图像智能分析及处理技术规范

1 范围

本文件为医疗图像智能分析及处理的关键技术指南，其中包含了相关术语和定义、医疗图像预处理、可视化、特征融合技术等重要内容。

本文件主要适用于智慧医疗领域，医学图像处理是医学领域中的一个重要领域。医学图像处理可以拟合人体模型，帮助医生看清楚内部结构，提高诊疗准确率。人工智能方法已在医学图像领域获得了长足的发展，主要包括图像分割、配准、融合、压缩、重建、分类等，涉及MR、超声、PET、CT、红外、中医望诊图像等。

2 规范性引用文件

本文件没有规范性引用文件。

3 术语和定义

下列术语和定义适用于本文件。

3.1

图像分割 Image Segmentation

图像分割是预测图像中每一个像素所属的类别或者物体。

3.2

可视化技术 Visualization Technique

医学图像可视化技术是指利用从实验中获得的、扫描器测得的、计算模型合成的医学数据，重建三维图像模型，并进行定性定量分析。

3.3

特征提取 Feature Extraction

特征提取技术是从图像中提取出具有代表性的特征信息，将这些信息转化为计算机可识别、分类的形式。

3.4

特征融合 Feature Fusion

指将来自不同源头、不同模态的医学图像（如CT、MRI、X光等）的特征信息有效地结合在一起。

3.5

图像配准 Image Registration

医学图像配准是将不同模态、不同时间或不同位置获取的医学图像进行空间上的对齐。

4 总体设计

4.1 基本原则

(1) 对标国家重大需求。以国家需求为研究命题导向，以研究成果转化落地为研究目标。

(2) 紧跟学科和技术前沿。以前沿科学技术驱动医疗图像智能分析及处理技术的发展创新，加速实现智能医疗领域升级。

(3) 密切联系实际医疗图像智能分析及处理技术。以向真正意义信息化、标准化和智能化方向发展为目标。

4.2 医疗图像智能分析及处理技术总体思路介绍

针对中医望诊图像、病理图像、心脏超声图像和皮肤图像的智能分析及分类问题，引入计算机视觉技术和强化学习理论是为了提高医疗图像分析的准确性和效率。为此，需要从医疗图像的预处理、特征提取、特征融合、疾病分类以及病势推演等方面确立技术规范与标准，以保证整个流程的可靠性和一致性。

首先，要考虑数据准备的规范化，包括建立完整的数据集，保证数据的一致性和准确性，以及确保数据采集和存储过程中的安全性和隐私保护。其次，在医疗图像的预处理阶段，标准应涵盖病灶检测和区域分割的精准性和可靠性。特征提取阶段需要明确有效的特征提取方法，以确保关键特征能够被准确捕捉。特征融合阶段需要确保不同来源的特征能够被无缝整合，以提高综合特征的表征能力。此外，针对疾病分类和病势推演，标准应涵盖多种算法的建模过程和模型的选择准则，以确保最终的分类结果和推演准确可靠。

然后，应确立相应的人体功能态势测评技术标准，以保证医疗图像分析结果与患者的实际病情相符合。这包括明确测评指标的选择依据、测评结果的解释规范，以及将测评结果与治疗决策相结合的标准化流程。

最后，通过这些严格的技术规范与标准，可以为构建具有自我学习和自主推理能力的医疗图像智能诊断及病势推演系统提供稳固的标准化支持，从而为医疗图像智能分析领域的发展奠定坚实基础。

4.3 医疗图像预处理

医学图像预处理的目的是获得更好的图像处理效果,以便对医学图像采取各种处理措施,消除无用信息的同时恢复真实有用的信息,一般包括医学图像分割、去噪和增强等措施。对医疗图像进行预处理工作,一方面,可以消除医疗图像中噪声,并增强图像纹理效果,实现提高图像质量的目的。另一方面,减少了医务人员对图像细节进行识别和分析处理的难度,有利于他们运用医学图像进行准确分析和诊断,大大提升了医学图像分类的效率以及准确性。

为实现医疗图像的自动化分析,首要任务是要将感兴趣区域从背景中分割出来。针对病灶区小、边缘模糊、存在伪影等导致医疗图像难以精确分割的问题,融合病灶形状结构先验知识,研究基于卷积神经网络的病灶图像分割方法,引入半监督特征学习探索脾胃反射区多尺度边界特征提取方法,利用卷积神经网络建立分割特征与边界特征的上下文聚合方法,实现对病灶的精确分割。

4.3.1 医疗图像分割

随着医学影像的快速发展,作为图像处理技术的重要组成部分,图像分割在医学图像的研究与应用中发挥越来越重要的作用。图像分割就是预测图像中每一个像素所属的类别或者物体。目前最常用的传统医疗图像分割方法主要包括基于阈值的分割方法、基于区域的分割方法、边缘分割方法、深度图像分割等。深度学习在图像处理任务上表现出强大的能力,因此成为解决图像分割问题上的首要选择,尤其是医学图像分割领域。医学图像分割在医学图像分析中起着至关重要的作用,可使病灶、脏器的病理结构变化更加明显,为临床诊断提供可靠的依据,对可视化、三维重建等相关技术的发展有较大的影响。

(1) 传统医疗图像分割

1) 基于阈值的图像分割

基于阈值的分割技术是图像分割领域常用的算法之一,算法原理即选定一个阈值将目标分为两个或多个目标区域,使同一目标区域内像素的灰度值相似性最高不同目标区域之间的像素点的灰度值差异性最高。基于阈值的图像分割算法的核心在于选择合适的阈值。阈值分割分为全局阈值分割和局部阈值分割,全局阈值分割是指整幅图像选用统一的阈值分割,在背景信息与前景信息对比非常明显的图像中能够很快的将背景信息从图像中分割出来。但是在背景信息比较复杂的图像中使用单一的阈值很难将不同的背景信息目标块分割出来,这时候就需要局部阈值分割,即在不同的局部区域选用不同的阈值。

2) 基于区域的图像分割

基于区域的图像分割就是把具有相似性质的像素点进行连通,从而慢慢的组合成最终

的分割区域结果。它主要是利用了图像的局部空间信息，能够有效地克服其他方法图像分割空间小的缺点。在基于区域的图像分割中，如果从全图出发，按区域属性特征相似的原则决定每个像素的区域归属，形成区域图，即区域生长的分割方法。如果从像素点出发，按区域属性特征相似的准则，将属性接近的像素点聚集为区域，则是区域增长的分割方法。如果综合利用上述两种方法，先将图像分割成小的区域，再根据不同小区域之间的相似性进行合并形成大区域，就是分裂合并的方法。

3) 基于边缘的图像分割

基于边缘的图像分割方法的主要理论依据是边缘检测理论，图像中背景信息与前景信息之间不连续像素的集合即为图像的边缘。这类算法通过检测相邻像素灰度值之间的差异性来捕获背景信息的边缘。常用的边缘检测方法有空域微分算子法、基于曲面拟合的方法、小波多尺度检测方法、基于数学形态学的边缘检测方法。

(2) 基于深度学习的医学图像分割

鉴于基于深度学习的图像处理方法具有自我学习能力强、适应能力强等优点，许多基于卷积神经网络的模型已经达到了很好的分割性能，在医学图像分割的研究中取得了较好的成果。基于深度学习的医学图像分割方法可以分为语义分割和实例分割，语义分割是以像素为单位、根据像素的语义信息进行归类；而实例分割包含检测和描述两个层面，对于图像的预测是基于实例的，医学图像中目标的类别比较少，因此常采用基于像素分类的语义分割方法。分割目标的先验信息（如先验形状和结构）对分割任务有良好性能影响，如形状信息有利于增强模型的鲁棒性和可解释性。

1) 基于深度学习的半监督图像分割方法

半监督图像分割方法介于完全监督和无监督之间，它需要有标注数据和无标注数据共同训练模型。目前深度学习方法在医疗实践的各个领域蓬勃发展，半监督学习在有标注数据匮乏的情况下，在医学图像分割中取得了良好效果。为了利用未标注数据进行半监督医学图像分割，一种简单直观的方法是给未标注数据生成伪标签。伪标签通常是通过迭代生成的，其中模型通过学习自身对未标注数据的预测来迭代提高伪标签的质量。基于深度学习的半监督学习方法大致分为基于伪标签的方法、基于一致性正则的方法以及混合方法。一致性正则的方法不追求得到无标注数据的伪标签，而是通过对无标注数据加入不同的噪声干扰，约束网络对加噪声的图像产生相同的预测结果，提高网络抗干扰能力，增强网络鲁棒性。对半监督医学图像分割方法，在神经网络训练时加入目标物体的解剖先验，通过调整网络在不同区域优化的权重，让网络根据重要性有侧重地学习，用先验信息指导网络训练。

2) 基于卷积神经网络的图像语义分割

随着深度学习的兴起，利用深度学习体系结构进行医疗图像分割，尤其是卷积神经网络（Convolutional Neural Network, CNN），其在检测准确率和效率方面都更优于传统的算法。CNN 是以生物的视知觉机制为基础原理设计的，是一种深度学习模型。卷积神经网络最明显的特征是网络中具有卷积结构，能够有效减少深层参数量，可以进行特征提取和分类，通过多次卷积、池化的操作不断加深网络，从而获得多尺度的感受野来贴合不同尺寸的目标。基于深度卷积神经网络的语义分割方法，将图像通过卷积神经网络提取特征，然后进行像素分类，得到语义分割图像。语义分割常用神经网络：AlexNet、VGGNet、VGGNet、ResNet。

基于编码器—解码器架构的变体是当前医学图像分割中最主流的网络模型，如完全卷积网络 FCN 和 U-Net。其中基于 FCN 分割方法的一个主要特点是结合多尺度策略来搭建网络模型以提取包含多尺度信息的特征图，其包含详细的纹理信息和丰富的上下文信息，利于提升模型的精度。为了在获得高级语义特征的基础上保留更多的结构信息，U-Net 将编码器—解码器结构与跳跃连接结合，使网络在解码过程中融入编码端低级特征，具有优良的分割性能。FCN 因其感受野大小受到限制，无法获取足够的全局上下文信息，而语义分割往往需要丰富的上下文信息以聚合生成精确的像素分类结果。上下文信息的聚合主要有三种：基于多尺度的方法，基于注意力的方法和基于随机场的方法。实时图像语义分割算法可以分为采用模型压缩，比如网络剪枝、低秩分解、参数量化和知识蒸馏；设计轻量化模型，通过优化网络结构，能够在不损失精度的同时降低模型的复杂度和所需的推理时间。实时分割算法更加注重降低网络的参数量和计算成本，以达到更快的推理速度，但这不可避免地会损失精度。在深度卷积网络中，感受野大小决定着网络可以获得多大范围的语义上下文信息，扩张卷积被用来增加网络感受野从而提升分割性能。

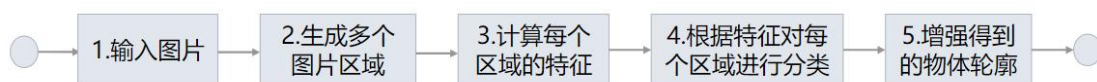


图 4-1 图像语义分割流程

4.3.2 医疗图像去噪

最初采集到的原始医学图像大多数都是含噪图像，这些噪声的存在对医学图像分析与处理的影响很大，一定程度上增加了医务人员对图像细节进行识别和分析处理的难度。如果不

能及时进行图像去噪,原始图像中的噪声会在之后特征提取和图像增强中进一步延续和放大,对医务人员的正常诊断造成更加严重的干扰,一定程度上造成误诊率上升。因此,有必要选择合适的图像去噪技术对医学图像进行预处理,消除或减少图像中的噪声,以降低对医学图像增强、分割和特征提取等后续图像处理过程的不利影响。在医学图像去噪领域,平滑技术是目前最常用的技术,包括空间域去噪法和频域去噪法两大类。

(1) 空间域去噪法:指通过采用不同图像平滑模板对原始图像进行卷积处理,在医学图像平面上修改灰度,达到抑制或消除噪声的目的,主要包括高斯滤波、算术均值滤波和中值滤波。

(2) 频域去噪法:指通过对图像进行变换后,选用适当的频率带通滤波器进行滤波,经反变换后获得去噪图像,主要包括小波变换和基于稀疏变换去噪。

4.3.3 医疗图像增强

医学图像在产生、传输和存储过程中,由于受光源、成像系统等各种复杂因素的影响,不可避免地会导致出现不同程度地清晰度下降、对比度偏低和包含噪声等降质现象。为了便于后续分析与处理,一般采用图像恢复和图像增强两种技术提高图像质量,其中,图像增强技术在图像处理领域中的应用非常广泛。所谓的图像增强技术一般指根据图像特点和处理目的加强图像的整体或局部特性,很好地保留了图像边界和结构信息以及突出图像中的某些性质等,提高了图像的可判读性,改善了图像质量,同时,使得图像变得清晰,便于医务人员分析医学图像,并从中获得更多有价值的信息。

(1) 直方图均衡化:使变换后的灰度分布更加的均衡,描述更多图像细节。

(2) 对比度拉伸:基于灰度变换的图像增强,使图像亮度达到理想的状态。

(3) 图像锐化:补偿图像的轮廓,增强图像的边缘及灰度跳变的部分,使图像变得清晰。

4.4 医学图像可视化技术

医学图像可视化技术是指利用从实验中获得的、扫描器测得的、计算模型合成的医学数据,重建三维图像模型,并进行定性定量分析,为用户提供具有真实感的三维医学图像,使人们更清楚地认识蕴涵在体数据中的复杂结构。医学影像数据一般来源于医院的CT或者MRI等设备,医学序列图像经三维重建得到的三维数字可视化医学模型,相比于二维图像能提供组织器官更加直观的三维立体视觉、显示更加复杂的空间结构,便于医生多角度多层次地观察和分析,并且能够使医生有效参与数据处理与分析的过程,能帮助医生做出更加准确的判断。




图 4-2 医学图像可视化流程

由图可知，医学图像可视化过程需要先读取 CT 或 MRI 图像切片数据，根据所需的某个器官或者某个图像区域对 CT 图像进行分割，接着再对分割后的图像进行三维重建，便于医生更直观地观察病灶尺寸，确定病灶在器官中的位置信息。重建后的结果能够提供实时交互功能，供医生在不同的观察角度对器官或者器官内存在的病变进行观察。

三维图像可视化是通过处理一系列二维图像实现三维重建的技术。

医学图像文件中的图像信息往往以体数据的方式存储，根据所要可视化的内容，可以将医学图像的可视化划分为面绘制和体绘制。

4.4.1 基于面绘制的三维重建

面绘制是三维可视化的主要方法之一，在医学图像的三维可视化中应用也十分广泛。面绘制应用于提取整个数据空间中的某些感兴趣的数据（如从头颅中提取颅骨），即对一系列二维断层图像组成的体数据进行边缘检测等分割处理，根据这些提取出来的数据形成等值面，从而能够还原出感兴趣物体的三维医学模型，实现多层面显示，这样医学工作者就能够比较直观、整体地了解目标物体的信息，从而更加有效地对数据进行处理与分析。这在仿真手术、辅助诊断、图形引导手术、虚拟内窥镜等领域都具有重大意义。面绘制的流程主要如下：

第一步：阈值提取。根据医学影像设备数据采集的特点，医学图像中根据组织结构的密度等不同特性生成的图像灰度值的不同，设定相应的阈值，就能够从医学图像中找到感兴趣物体的位置；

第二步：等值面生成。经过阈值提取后，通过一定的规则形成拓扑结构从而生成物体表面；

第三步：光照模型。通过设置光源与视线形成富有真实感的物体模型。面绘制的核心问题是如何在体数据中构造等值面。从处理的基本元素来分，目前主要有两种方式：基于切片的面绘制以及基于体素的面绘制。

4.4.2 基于体绘制的三维重建

体绘制主要目标是将三维体数据投影在二维平面上,绘制后结果由多个体素数据组成的 3 维数组构成。直接体绘制也称为体绘制,是非常重要的可视化算法。与面绘制方法不同,体绘制技术并不生成中间过渡图形,直接体绘制则将体数据集合中的每个体素看做一个具有一定属性颜色、不透明度的个体,通过累加体数据中每个数据对相应二维像素点的贡献值,直接从三维体数据中产生二维图像,体绘制技术能够完整得展示体数据的细节。与面绘制技术类似,体绘制中也运用到光照模型,不同的是,体绘制以物体对光的吸收原理为基础,而面绘制中的光照模型则作为增强物体真实感的补充,起渲染作用。体绘制算法的核心问题在于如何计算体数据对像素点的贡献以及图像的合成。

常见的体绘制算法有射线投射法、足迹法、剪切-曲变法、纹理映射法、频域体绘制法以及基于小波的体绘制。

体绘制技术已有很多相关算法,虽然实现过程有差别,但这些算法大致流程概括为:数据采集及获取、数据预处理、体数据分类及体数据绘制四个阶段。本文着重介绍医学图像体绘制流程,为后续研究及改进体绘制中的光线投射算法和传递函数设计方法提供相关理论基础,如图 2-8 所示。




图 4-3 医学图像体绘制流程

第一阶段:体数据采集及获取。利用医学图像成像设备对人体进行断层扫描,采集到二维断层数字图像序列,获取的 CT、MRI 等图像序列,一般采用 DICOM 格式存储。

第二阶段:数据预处理。数据预处理的目的是为体数据分类效果提供保障。

第三阶段:体数据分类。体数据分类是体绘制最关键的阶段,直接决定着体绘制效果。用传递函数对体数据进行分类,传递函数把体数据属性(如颜色及不透明度等)映射成相对应的光学属性。

第四阶段:体数据绘制。体数据绘制是把第三阶段的分类结果渲染到屏幕上,以二维图像形式在屏幕上显示。

4.5 医学图像特征提取

特征提取技术是从图像中提取出具有代表性的特征信息,将这些信息转化为计算机可识别、分类的形式。在医学图像处理中,特征提取技术可以用于疾病的诊断、医学图像的分割与配准等领域,是医学图像处理的重要组成部分。图像处理要求选取的特征能很好地描述特征,特征提取的原则是:特征的提取应容易方便。选取比较稳定的特征,即特征应对噪声干扰和无关联的变化不敏感。最为重要的是选取的特征一定要有很强的分区能力。此外,在特征提取中还要考虑一定的先验知识。所谓的图像特征一般指图像有别于其他类型图像的特性或者属性,包括图像的颜色、纹理、形状和空间关系特征等4个方面。由于从图像中所提取的特征能准确描述图像本质的、重要的特征,因而图像特征提取的质量直接影响到图像分类结果的准确与否。

4.5.1 基于颜色的特征提取

颜色特征最能直观的反映出图像中所含物体或场景的表面性质,图像中的每一个像素点都有自身的存在意义与贡献。颜色特征不仅能描述全局特征而且还可以捕捉图像中的局部特征,同时颜色特征本身还具有很好的抗敏感性。虽然颜色特征有其本身的诸多优势,但也有其短板,颜色特征是基于像素点的特征,因此无法涵盖区域像素之间的关系信息、多尺度信息等。常用的颜色特征提取方法有:颜色直方图、颜色集、颜色矩、颜色聚合向量、颜色相关图等。

4.5.2 基于纹理的特征提取

纹理是图像中不同区域的纹路和织构,反映了区域内像素点的分布情况。纹理是一种重要的视觉线索,对图像的粗细、疏密有很好的区分能力。纹理特征是全局特征,与颜色特征都具有对图像中所含物体或场景表面性质的描述能力,但区别在于纹理特征是一种区域性特征,其优势是符合人类对客观事物的视觉习惯,具有旋转不变性和强抗噪性,但缺点是容易受到光照、反射等情况的影响。按照性质可将纹理特征提取方法划分为四类:基于统计的方法、基于信号处理的方法、基于模型的方法和基于结构的方法。基于统计方法是纹理特征提取方法中最常用的一种方法,主要是基于图像的统计特性对纹理图像进行分析。虽然图像的纹理分布情况存在一定的随机性但在一定程度上统计特性却更为突出。

4.5.3 基于形状的特征提取

图像特征是图像的一种稳定属性,并不随图像尺度、亮度、视角的变化而变化,具有局部不变性。形状特征包括:侧重于物体外边界的轮廓特征和针对整个形状区域的区域特征。物体其实都是点、线、面的组合体,常见的形状特征提取方法有:边界特征法、集合参数法、

傅里叶形状描述符法、形状不变矩法等。

4.5.4 基于空间关系的特征提取

空间关系是指图像中的多个分割目标间的相互空间位置信息或相对方向关系信息。空间位置信息可分为强调目标之间的相对情况的相对空间位置信息和强调目标之间的距离大小以及方位的绝对空间位置信息两大类。相对方向关系是指连接/邻接关系、交叠/重叠关系和包含/包容关系等。空间关系特征有一定的辨别力，但对图像不具有旋转不变性以及尺度不变性。提取图像的空间关系特征一般有两种方式：（1）根据某种分割算法将图像先分割成多个区域，然后在这些区域提取特征并建立索引；（2）直接将图像分割成均匀的规则区块，然后提取各个区块特征并建立索引。常需要配合其它特征来描述图像的内容。常用的提取图像空间关系特征的方法有两类：基于模型的姿态估计方法和基于学习的姿态估计方法。

4.5.5 基于深度学习的特征提取

基于深度学习的方法解决了传统机器学习方法需要花费时间，手动提取图像特征并选择合适方法进行降维的问题，同时能够获得高级特征。多尺度特征提取模块提取图像的多尺度特征，深度挖掘病灶区域与周边组织的上下文信息增强网

络的特征提取能力。使用深度特征提取模块从通道和空间两方面着重关注病灶区域的局部特征，削弱不相关信息影响，加强对病灶区域辨识能力。运用空洞卷积并联构造增强特征提取模块，在不损失图像特征信息前提下提升分类精度，运用卷积替换策略在减少参数量的同时加强分类性能。

特征提取作为语义分割任务中的关键步骤，主要通过深层卷积操作来逐步由浅到深地提取图像语义信息。特征提取结构可以有效地获取图像中的各类特征信息，但在具体的视觉任务中，需要网络聚焦目标相关特征，对于目标特征关注度的提升通常采用注意力机制。多尺度特征融合主要针对目标尺度变化问题，利用深层特征和浅层特征逐步融合的方式来增强网络的尺度不变性。深度神经网络通常采用卷积操作，卷积是一种局部连接和共享参数的连接方式，可以学习数据中的局部特征，具有多层结构的深度神经网络能够将浅层的局部特征整合成具有高度抽象和表达能力的全局特征，能够较好地提取出高维数据中的有效特征。典型的深度网络如 AlexNet、VGG、Inception 网络及残差网络（ResNet）。这些深度卷积网络都极大地提升了特征提取的性能。

针对传统医疗图像表现特征缺乏深层语义信息的问题，结合医疗图像病灶分割结果，研究病灶的全局深度特征提取方法，面向重点关注区域的局部特征，探索基于多尺度与自适应注意力机制的局部深度特征提取方法，建立全局深度特征与局部深度特征的聚合机制。

4.6 医学图像特征融合技术

针对高维、异构、冗余、含噪的多元病灶特征，研究基于图变换神经网络的多元望诊特征融合策略，探索基于轴向门控注意力机制的融合特征判别性增强方法，实现对可变、虚假、冗余等特征的消除。

医学图像特征融合技术是指将来自不同源头、不同模态的医学图像（如 CT、MRI、X 光等）的特征信息有效地结合在一起，形成一个综合的、更全面、更准确的图像特征表示。这样的技术有助于改善医学图像的诊断、治疗和监测效果，为医生提供更全面的信息，增强医学图像的诊断准确性和可靠性。

4.6.1 多元特征处理

(1) 特征降维和选择

针对高维特征，可以使用降维技术，如主成分分析（PCA）或流形学习方法，将特征投影到低维空间，保留主要信息的同时减少冗余。如图 4-4 所示，特征降维示意图。

第一步：对数据进行标准化处理，确保每个特征的取值范围相近。这是因为 PCA 等降维方法依赖于数据的方差，如果特征之间的尺度差异很大，会影响降维的效果。将标准化后的数据计算特征之间的协方差矩阵。协方差矩阵反映了特征之间的线性关系程度。

第二步：对协方差矩阵进行特征值分解，得到特征值和对应的特征向量。特征向量是新的特征空间的基向量，而特征值表示这些基向量的重要程度。将特征值按从大到小的顺序排列，选择前 k 个特征值对应的特征向量作为主成分。这里的 k 是降维后的维度，通常是根据数据的方差贡献率来确定。

第三步：将原始数据与选取的主成分组合，将数据投影到低维空间，得到降维后的数据集。




图 4-4 特征降维示意图

对于冗余特征，可以使用特征选择方法，如相关系数分析或互信息，筛选出对任务有用的特征，排除冗余信息。如图 4-5 所示，为特征选择示意图。



图 4-5 特征选择示意图

第一步：确定特征选择的评估指标，这取决于具体的问题。例如，如果是回归问题，可以使用相关系数或皮尔逊相关系数作为评估指标；如果是分类问题，可以使用互信息或基于模型的特征选择方法等。对每个特征计算所选的评估指标，衡量每个特征与目标变量之间的关联程度或重要性。

第二步：将特征根据评估指标进行排序，或者设置一个阈值，选择具有较高得分的特征。也可以采用基于模型的特征选择方法，如递归特征消除（Recursive Feature Elimination, RFE）等。

第三步：将选取的特征组合成新的数据集，作为输入用于建模。

（2）异构特征融合

将来自不同医学影像模态或处理方法的异构特征进行融合，可以采用图像配准和对齐技术，确保不同特征之间空间和尺度的一致性。使用特征融合技术，如卷积神经网络中的多分支结构，或者图神经网络中的图融合模块，将异构特征进行有效的融合，从而获取更全面的信息。

第一步：对不同模态或处理方法的医学影像进行图像配准和对齐，确保它们在空间和尺度上保持一致。对经过配准和对齐的影像，从每个模态或处理方法中提取特征。这些特征可以是传统的图像特征，也可以是基于深度学习的卷积神经网络提取的高级特征。

第二步：将从不同模态或处理方法提取的特征进行融合。可以使用卷积神经网络中的多分支结构，将每个模态的特征输入到不同的分支，然后通过一定的融合策略（如拼接、加权平均等）将它们合并。另一种方法是使用图神经网络中的图融合模块，将特征表示为图结构，然后通过图融合算法将不同模态的特征融合在一起。

第三步：将融合后的特征用于建模或其他医学图像处理任务。这些融合后的特征通常能

够提供更全面的信息，有助于改进诊断、分割、分类等医学影像分析任务的性能。

(3) 含噪特征处理

对于含噪特征，可以采用预处理方法，如滤波或去噪技术，来减少噪声的影响，并提升特征的质量。滤波可以平滑数据并去除高频噪声，去噪技术专门处理噪声，例如小波去噪等。

引入鲁棒性增强的特征学习方法，如对抗性训练或稀疏表示等其他技术，可以增强特征的鲁棒性，提高对噪声的容忍度。

4.6.2 医学图像配准

医学图像配准是将不同模态、不同时间或不同位置获取的医学图像进行空间上的对齐，使它们在相同的坐标系下进行比较和分析的过程。医学图像配准对于疾病诊断、手术规划以及治疗评估等方面具有重要意义。医学图像配准算法如图 4-6 所示。

第一步，对要配准的图像进行预处理，包括去除噪声、平滑图像、增强对比度等，以提高配准的准确性。从每幅图像中提取特征点或特征描述子，用于后续的图像匹配。常用的特征提取方法包括 SIFT（尺度不变特征变换）、SURF（加速稳健特征）等。

第二步，采用搜索策略来匹配特征点，常见的有暴力搜索（brute-force）和 k-d 树等近似搜索方法，以找到匹配的特征点对。在要配准的图像中，根据特征点或描述子之间的相似度，进行特征点匹配。常见的匹配算法有最近邻匹配、最佳双向匹配等。基于特征点的匹配结果，选择适合的变换模型来描述图像之间的几何变换关系。常见的变换模型包括刚体变换、相似变换、仿射变换和非刚性变换等。

第三步，根据选定的变换模型，对图像进行配准。这涉及到将目标图像转换到参考图像的坐标系中，使它们对齐。配准后，通常需要对配准结果进行评估，检查是否达到预期的准确性和可靠性。如果需要，可以进行迭代优化，改进配准结果。

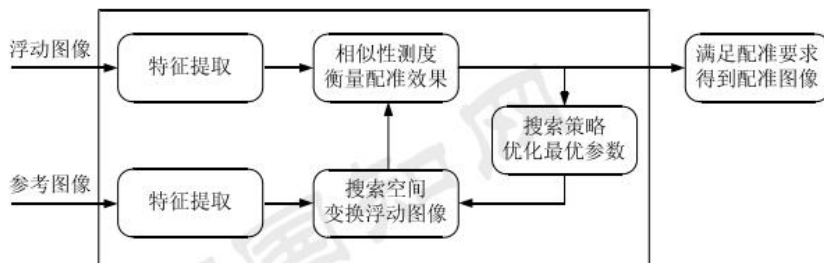


图 4-6 医学图像配准算法

4.6.3 基于图变换神经网络的多元望诊特征融合策略

望诊是中医传统诊断方法之一，涉及到对患者的脸部、舌苔等特征进行观察和分析。图变换神经网络是一种基于图数据的深度学习方法，能够有效处理非结构化的图像数据。在望

诊图像特征提取和图变换神经网络基本原理的基础上,设计多元望诊特征融合策略。这个策略将综合利用脸部特征和舌苔特征,通过图变换神经网络将它们进行有效融合,以获得更具诊断能力的综合特征。

将脸部特征和舌苔特征转换成图形数据,构建望诊特征图。设计适合望诊特征图的图变换神经网络结构,用于学习和融合多元望诊特征。在图变换神经网络中,进行多元望诊特征的融合与学习。这包括基于图卷积和注意力机制的特征融合,以及端到端的学习过程。通过以上步骤,可以实现基于图变换神经网络的多元望诊特征融合。

4.6.4 基于轴向门控注意力机制的特征判别性增强方法

特征判别性增强方法是为了提高医学图像特征的判别能力,减少冗余特征和排除虚假特征而设计的一种技术。

在医学图像特征融合中,由于特征可能存在冗余和噪声,对于重要特征的判别能力的增强尤为重要。特征判别性增强方法旨在通过引入轴向门控注意力机制,对多元望诊特征进行加权和选择,从而提高重要特征的判别能力,降低冗余和噪声特征的影响。轴向门控注意力机制通过学习到的权重向量,自动地对特征进行加权,使得对于关键的特征具有较高的权重,而对于无关或冗余的特征具有较低的权重,从而增强特征的判别性。

轴向门控注意力机制由两个主要部分组成:门控机制和注意力机制。在门控机制中,引入门控单元来学习特征的重要程度,它通过学习到的门控权重来控制特征的激活与抑制。在注意力机制中,通过计算特征与门控权重的点积得到特征的注意力权重,进而对特征进行加权。这个过程能够使得在特征融合过程中,重要的特征得到强化,无关的特征得到抑制,从而增强特征的判别性。

将轴向门控注意力机制引入多元望诊特征融合策略中。在特征融合阶段,将望诊图像中的脸部特征和舌苔特征分别作为输入,并通过轴向门控注意力机制对它们进行特征判别性增强。注意力机制将计算不同特征与门控权重的点积,得到每个特征的注意力权重,然后将这些注意力权重与特征相乘,以得到特征加权后的结果。这样,将增强对于诊断重要的特征,抑制对诊断无关的特征,从而实现对多元望诊特征的优化和判别性增强。

4.7 疾病诊断及病势推演技术

围绕中医望诊图像、病理图像、心脏超声图像、皮肤图像,依据病灶融合特征与中西医辨证/辨病体系,研究基于因果强化学习的疾病智能诊断策略,探索疾病的病势转化与动态推演模型,实现对患者的智能准确诊断。

4.7.1 构建因果推断模型

在医学图像分析和疾病智能诊断领域,准确理解疾病与医学图像之间的因果关系对于提高诊断准确性和效率至关重要。因此,本标准旨在构建因果推断模型,从大量的医学图像和病例数据中挖掘出特征之间的因果关联,以帮助理解不同特征之间的因果影响,并为智能诊断器提供更准确的信息和决策支持。

第一步:进行数据预处理和特征工程,确保数据的质量和准确性。

第二步:基于预处理后的特征数据,需要进行因果关系挖掘。这可以通过因果推断方法来实现,如因果图模型、结构方程模型等。因果关系挖掘的目标是找出不同特征之间的因果关系,即哪些特征对于疾病诊断起到关键作用。

第三步:在因果关系挖掘的基础上,构建因果推断模型。这个模型可以是基于统计学方法的,如概率图模型,也可以是基于机器学习的,如深度神经网络。模型的选择和构建需要根据具体任务和特点进行考虑。构建完因果推断模型后,需要对模型进行评估和优化。评估可以使用交叉验证等方法来验证模型的性能和泛化能力。根据评估结果,对模型进行优化,调整模型参数和结构,以提高模型的性能和效果。

4.7.2 疾病智能诊断器构建与训练

在构建疾病智能诊断器之前,需要设计多模态神经网络,用于融合来自不同特征提取方法的多种特征。多模态神经网络的设计涉及到网络的结构、层次、连接方式等方面,需要综合考虑数据特点和任务目标。

首先,需要在多模态神经网络上应用强化学习算法。强化学习算法的选择可以根据问题的具体特点和要求,如深度Q网络(Deep Q-Network, DQN)、深度确定性策略梯度(Deep Deterministic Policy Gradient, DDPG)等。

然后,在多模态神经网络和强化学习算法的基础上,开始对智能诊断器进行训练和优化。训练过程需要使用丰富的医学图像数据,结合强化学习的奖励机制,通过反向传播算法来更新网络参数,使智能诊断器逐渐学习到对疾病的诊断能力。

最后,完成智能诊断器的训练后,需要对其进行评估。这可以通过交叉验证、测试集评估等方法来进行。同时,还需要检验智能诊断器的泛化能力,即在新的未见过的医学图像数据上是否能够有效地进行诊断。

4.7.3 病势转化理论与模型设计

病势转化是指疾病在不同阶段的发展演变过程,它反映了疾病的临床特点和治疗效果。疾病病势转化理论是基于临床实践和病例观察得出的总结和认识,通过分析疾病病程中的不同状态和特征,揭示疾病的发展规律。

首先，基于病势转化理论，设计疾病病势转化模型，用于预测患者的疾病发展情况和可能的转化状态。模型设计将涉及到数据处理、特征提取、状态转换预测等步骤。收集大量的病例数据和临床观察数据，对其进行预处理和整理。预处理步骤可能包括数据清洗、异常值处理、缺失值填充等，以确保数据的质量和完整性。

然后，在数据预处理后，进行特征工程和提取。特征工程可能包括形状特征、纹理特征、颜色特征等的提取，以及对不同特征之间的相关性进行分析和选择。

在特征提取后，将构建状态转换预测模型。这个模型可以是基于机器学习的方法，如决策树、支持向量机（SVM）、递归神经网络（RNN）等，也可以是基于深度学习的方法，如长短期记忆网络（LSTM）、图神经网络（GNN）等。模型的选择将根据数据的特点和任务的要求来决定。

最后，在模型构建后，将使用数据集进行模型的训练和优化。训练过程中，需要将数据集划分为训练集和测试集，通过反向传播算法来更新模型参数，使模型逐渐学习到状态转换的规律。

4.7.4 疾病动态推演方法与实现

在疾病动态推演中，需要收集患者的临床数据和医学图像数据，并对其进行预处理和整理。数据预处理步骤可能包括数据清洗、去噪、归一化等，以确保数据的质量和可靠性。

在数据预处理后，对疾病数据进行动态建模和时间序列分析。动态建模可以采用状态空间模型、马尔可夫过程、变分自回归模型等方法，以建立疾病病势的动态变化模型。时间序列分析可以用于探索疾病数据中的趋势、周期性等特征，从而更好地理解疾病的发展规律。

首先，基于动态建模和时间序列分析的结果，设计疾病动态推演方法。方法的选择将根据数据特点和任务目标来决定。

然后，在设计好疾病动态推演方法后，进行模型的实现和预测。通过使用病例数据对模型进行训练，使其学习到疾病动态的规律和特征。之后，可以用模型来进行疾病病势的预测和推演，实现对患者未来状况的预测。

最后，在模型实现和预测后，需要对模型进行评估和优化。评估可以使用交叉验证、测试集评估等方法来验证模型的性能和泛化能力。根据评估结果，可以对模型进行优化，调整模型参数和结构，以提高模型的性能和效果。