



(12) 发明专利申请

(10) 申请公布号 CN 119941710 A

(43) 申请公布日 2025.05.06

(21) 申请号 202510316087.1

G06V 10/774 (2022.01)

(22) 申请日 2025.03.18

G06V 10/82 (2022.01)

(71) 申请人 北京理工大学

G06N 3/0464 (2023.01)

地址 100086 北京市海淀区中关村南大街5
号

G06N 3/048 (2023.01)

申请人 中国医科大学附属盛京医院

(72) 发明人 李伟 刘欢 秦庚 吴安华 程文
郭松溢

(74) 专利代理机构 四川省方圆智云知识产权代
理事务所(普通合伙) 51368

专利代理人 王悦

(51) Int.Cl.

G06T 7/00 (2017.01)

G06T 7/10 (2017.01)

G06V 10/764 (2022.01)

权利要求书2页 说明书6页 附图4页

(54) 发明名称

一种基于原型注意力网络的高光谱脑肿瘤
手术引导分割方法

(57) 摘要

本发明公开了一种基于原型注意力网络的高光谱脑肿瘤手术引导分割方法。通过以下步骤实现：通过术中高光谱成像平台采集脑肿瘤的高光谱图像数据，并构建用于训练的标准数据集；设计并构建基于原型注意力网络的高光谱图像分割模型，通过自适应聚焦重要特征，增强肿瘤与正常组织之间的差异性；使用标准数据集对模型进行训练，优化网络参数，从而提高分割精度和实时性能；将训练好的高光谱图像分割模型部署至高光谱图像采集平台，实时处理采集到的脑肿瘤高光谱图像，输出分割结果并生成手术引导信息。本发明的优点是：有效提高脑肿瘤术中实时分割的准确性和效率，为手术提供精准引导。

构建标准化数据集

利用高光谱标准采集平台采集脑部区域图像

数据进行反射板校正等标准化操作

对脑部区域进行逐位置采样，利用金标准判断其类别

构建标准化脑胶质瘤高光谱分割数据集（500手术）

1.一种基于原型注意力网络的高光谱脑肿瘤手术引导分割方法,其特征在于,包括以下步骤:

步骤1:通过术中高光谱成像平台采集脑肿瘤的高光谱图像数据,并构建用于训练的标准数据集;

步骤2:设计并构建基于原型注意力网络的高光谱图像分割模型,通过自适应聚焦重要特征,增强肿瘤与正常组织之间的差异性;

步骤3:使用标准数据集对高光谱图像分割模型进行训练,优化网络参数,以提高分割精度和实时性能;

步骤4:将训练好的高光谱图像分割模型部署于高光谱图像采集平台,实时处理采集到的脑肿瘤高光谱图像,输出分割结果并生成手术引导信息。

2.根据权利要求1所述的高光谱脑肿瘤手术引导分割方法,其特征在于:步骤1包括以下子步骤:

步骤1.1:通过高光谱采集平台采集高质量的术中高光谱图像,同时获取对应的组织样本和病理“金标准”诊断结果,以确保数据集标注的准确性;

步骤1.2:利用病理“金标准”诊断结果对高光谱图像进行标注,针对离体的脑肿瘤组织进行标注,确定肿瘤的不同类别及其边界;

步骤1.3:将高光谱数据分为训练数据、验证数据,和测试数据,确保评估的全面性;

步骤1.4:将高光谱图像数据与对应的类别数据整理,进行标准化处理,以形成脑肿瘤分割的标准训练数据集。

3.根据权利要求1所述的高光谱脑肿瘤手术引导分割方法,其特征在于:步骤2包括以下子步骤:

步骤2.1:基于原型注意力网络的高光谱图像分割模型,结合原型学习和注意力机制,通过聚合相似特征来增强肿瘤特征的表示能力;

步骤2.2:根据脑肿瘤分割的训练数据集,设置高光谱图像分割模型的输入和输出大小,配置所需的参数值,包括学习率、优化器函数和损失函数。

4.根据权利要求1所述的高光谱脑肿瘤手术引导分割方法,其特征在于:步骤3包括以下子步骤:

步骤3.1:设置高光谱图像分割模型的训练轮数,以确保模型充分学习和损失收敛;

步骤3.1:将高光谱图像训练数据集输入到步骤2构建的高光谱图像分割模型中进行训练,高光谱图像分割模型在训练过程中不断调整参数以提高分割效果;

步骤3.1:训练完成后,保存优化后的网络参数和权重文件,以便后续使用。

5.根据权利要求1所述的高光谱脑肿瘤手术引导分割方法,其特征在于:步骤4包括以下子步骤:

步骤4.1:将训练后的高光谱图像分割模型部署在高光谱标准采集平台上,完成近实时分割;

步骤4.2:获取待分割的术中高光谱图像,确保采集方式和仪器与训练数据一致;

步骤4.3:对待分类的高光谱图像进行处理,以符合网络输入要求;

步骤4.4:将处理后的高光谱图像输入至训练好的原型注意力网络;

步骤4.5:获得高光谱图像全图的分割结果,识别出脑肿瘤类型,并生成分割报告,为医

生提供术中决策支持。

6. 根据权利要求1至5其中一项所述的高光谱脑肿瘤手术引导分割方法，其特征在于：所述原型注意力网络模型结合了原型学习和注意力机制，通过聚焦于脑肿瘤的关键特征，提高了肿瘤区域与正常组织之间的差异性，从而提升分割精度。

7. 根据权利要求6所述的高光谱脑肿瘤手术引导分割方法，其特征在于：所述原型注意力网络采用多头原型注意力模块，以增强特征提取的多样性，缓解过拟合现象并提高模型的鲁棒性。

8. 根据权利要求1所述的高光谱脑肿瘤手术引导分割方法，其特征在于：所述高光谱图像数据包括多个波段的光谱信息，并采用标准化处理以适应深度学习模型的训练需求。

一种基于原型注意力网络的高光谱脑肿瘤手术引导分割方法

技术领域

[0001] 本发明涉及医学影像处理与人工智能技术领域,特别涉及一种基于原型注意力网络的高光谱脑肿瘤手术引导分割方法。

背景技术

[0002] 脑肿瘤的手术切除对患者的治疗效果和生存预后至关重要。然而,由于脑肿瘤与正常脑组织的边界模糊,术中准确识别和切除肿瘤区域极具挑战性。在传统的术中检测技术中,外科医生主要依赖于术中病理、影像学资料和手术导航系统,这些方法虽具有一定的辅助作用,但仍存在多种局限性。

[0003] 现阶段的术中病理检测依赖快速冰冻切片技术,病理学家可以在几分钟内获得组织样本的病理结果,从而帮助外科医生判断肿瘤的性质和边界。然而,此方法受到样本处理质量的影响,且需要依赖病理学家的主观判断,存在较高的误差风险。此外,基于MRI、CT等的手术导航系统虽然能够提供三维空间定位,但难以提供足够的实时细节,特别是在区分组织微小差异方面存在局限。

[0004] 在成像技术中,高光谱成像技术以其独特的高光谱分辨率,能够在空间分辨率基础上增加光谱信息,有助于检测和分析不同组织的光谱差异。高光谱成像的优势在于其可以提供每个像素点的光谱数据,通过区分组织的光谱特征,能够更好地识别肿瘤与正常组织的差异,成为医学影像领域的新兴工具。然而,高光谱数据的多维性和复杂性带来了实时处理的挑战,尤其是在术中近实时检测场景中,需要快速高效的算法来提取有效信息。

[0005] 为此,深度学习技术被引入高光谱图像处理领域,在脑肿瘤检测中取得了显著进展。传统的机器学习方法,如支持向量机(SVM)和K近邻(KNN),通过提取和分类光谱特征应用于脑肿瘤检测,但由于依赖手工特征提取,难以充分利用高光谱图像的多维信息,处理效果有限。近年来,卷积神经网络(CNN)等深度学习方法凭借自动特征提取和分类能力,在高光谱图像的分割和识别方面展现了更优的性能。

[0006] 此外,注意力机制的引入进一步提升了深度学习在医学影像中的应用效果。注意力机制能够动态调整特征的权重,使得网络可以聚焦于重要区域,减少背景噪声的干扰。在高光谱图像处理任务中,这类方法已经被证明可以提高分割精度和对目标区域的识别能力。然而,这些现有方法在实际应用中仍面临一定的局限性,如计算复杂度高、实时性不足,对信息的利用不充分。

[0007] 综上所述,现有的脑肿瘤术中检测方法在满足高精度的前提下,难以有效实现实时性和鲁棒性,且未能充分挖掘高光谱图像中的多维信息。因此,开发一种更加高效的分割方法,以实现高光谱图像的术中实时检测,对于提高脑肿瘤的术中检测精度具有重要意义。

发明内容

[0008] 本发明针对现有技术的缺陷,提供了一种基于原型注意力网络的高光谱脑肿瘤手术引导分割方法。特别适用于在手术过程中,通过高光谱图像实时分割脑肿瘤组织,以辅助

医生更精确地识别和切除肿瘤，减少对健康组织的损伤。

[0009] 为了实现以上发明目的，本发明采取的技术方案如下：

[0010] 一种基于原型注意力网络的高光谱脑肿瘤手术引导分割方法，包括以下步骤：

[0011] 步骤1：通过术中高光谱成像平台采集脑肿瘤的高光谱图像数据，并构建用于训练的标准数据集；

[0012] 步骤2：设计并构建基于原型注意力网络的高光谱图像分割模型，通过自适应聚焦重要特征，增强肿瘤与正常组织之间的差异性；

[0013] 步骤3：使用标准数据集对高光谱图像分割模型进行训练，优化网络参数，以提高分割精度和实时性能；

[0014] 步骤4：将训练好的高光谱图像分割模型部署于高光谱图像采集平台，实时处理采集到的脑肿瘤高光谱图像，输出分割结果并生成手术引导信息。

[0015] 进一步地，步骤1包括以下子步骤：

[0016] 步骤1.1：通过高光谱采集平台采集高质量的术中高光谱图像，同时获取对应的组织样本和病理“金标准”诊断结果，以确保数据集标注的准确性；

[0017] 步骤1.2：利用病理“金标准”诊断结果对高光谱图像进行标注，针对离体的脑肿瘤组织进行标注，确定肿瘤的不同类别及其边界；

[0018] 步骤1.3：将高光谱数据分为训练数据、验证数据，和测试数据，确保评估的全面性；

[0019] 步骤1.4：将高光谱图像数据与对应的类别数据整理，进行标准化处理，以形成脑肿瘤分割的标准训练数据集。

[0020] 进一步地，步骤2包括以下子步骤：

[0021] 步骤2.1：基于原型注意力网络的高光谱图像分割模型，结合原型学习和注意力机制，通过聚合相似特征来增强肿瘤特征的表示能力；

[0022] 步骤2.2：根据脑肿瘤分割的训练数据集，设置高光谱图像分割模型的输入和输出大小，配置所需的参数值，包括学习率、优化器函数和损失函数。

[0023] 进一步地，步骤3包括以下子步骤：

[0024] 步骤3.1：设置高光谱图像分割模型的训练轮数，以确保模型充分学习和损失收敛；

[0025] 步骤3.1：将高光谱图像训练数据集输入到步骤2构建的高光谱图像分割模型中进行训练，高光谱图像分割模型在训练过程中不断调整参数以提高分割效果；

[0026] 步骤3.1：训练完成后，保存优化后的网络参数和权重文件，以便后续使用。

[0027] 进一步地，步骤4包括以下子步骤：

[0028] 步骤4.1：将训练后的高光谱图像分割模型部署在高光谱标准采集平台上，完成近实时分割；

[0029] 步骤4.2：获取待分割的术中高光谱图像，确保采集方式和仪器与训练数据一致；

[0030] 步骤4.3：对待分类的高光谱图像进行处理，以符合网络输入要求；

[0031] 步骤4.4：将处理后的高光谱图像输入至训练好的原型注意力网络；

[0032] 步骤4.5：获得高光谱图像全图的分割结果，识别出脑肿瘤类型，并生成分割报告，为医生提供术中决策支持。

[0033] 进一步地,所述原型注意力网络模型结合了原型学习和注意力机制,通过聚焦于脑肿瘤的关键特征,提高了肿瘤区域与正常组织之间的差异性,从而提升分割精度。

[0034] 进一步地,所述原型注意力网络采用多头原型注意力模块,以增强特征提取的多样性,缓解过拟合现象并提高模型的鲁棒性。

[0035] 进一步地,所述高光谱图像数据包括多个波段的光谱信息,并采用标准化处理以适应深度学习模型的训练需求。

[0036] 与现有技术相比,本发明的优点在于:

[0037] 1.本发明通过结合原型学习和注意力机制,能够有效地聚焦于肿瘤区域,增强肿瘤与正常组织之间的差异性。这使得分割网络在脑肿瘤边界的识别上表现出高精度,尤其对于复杂的肿瘤边界和微小差异的区域,分割结果具有更高的准确性。与传统方法相比,本发明在肿瘤区域的分割上显著提高了精度,减少了背景噪声的干扰,提升了分割的细节表现。

[0038] 2.本发明通过高效的网络架构设计,能够快速处理术中采集的高光谱图像,并实时给出肿瘤分割结果。该技术适用于动态和快速变化的手术场景,能够为外科医生提供及时的分割信息,帮助医生在手术中做出更精确的决策,提高手术的安全性和效率。

[0039] 3.通过引入空间感知前馈网络模块,采用多尺度深度可分离卷积,模型能够有效处理高光谱图像中不同空间尺度的特征。该模块增强了网络的鲁棒性,使得在处理具有复杂空间特征和大规模数据时,模型能够保持稳定的性能,不受图像噪声和不同解剖特征的干扰。

[0040] 4.本发明所设计的原型注意力网络能够充分利用高光谱图像的多波段信息,在复杂的脑肿瘤图像中提取到更为丰富的特征。该技术不仅能够处理单一高光谱图像,还能够适应多模态数据的融合,为肿瘤分割提供更全面的信息支持,提高了分割结果的准确度和可靠性。

[0041] 5.传统的脑肿瘤分割方法往往依赖人工干预或手动调整阈值,而本发明采用了基于深度学习的自动分割方法,大大减少了人工干预的需求。网络能够自动完成高精度分割过程,降低了人工操作的复杂度,并减少了人为错误的可能性。

[0042] 6.本发明为脑肿瘤的精准分割和定位提供了高效工具,有助于医生在手术中进行更加精准的肿瘤切除。通过精确识别肿瘤边界,能够为个性化治疗方案的制定提供支持,提高患者的治疗效果和生存率。

[0043] 7.采用原型注意力机制对高光谱图像的空间和光谱信息进行深度融合,显著增强了肿瘤组织与正常组织的区分能力。特别是在肿瘤周围边缘部分,网络能够准确地识别出微小的病变区域,确保肿瘤的完全切除,避免残留。

附图说明

[0044] 图1为本发明实施例数据集构造流程图;

[0045] 图2为本发明实施例原型注意力网络构建流程图;

[0046] 图3为本发明实施例网络模型的训练、测试和部署流程图;

[0047] 图4为本发明实施例基于原型注意力网路的高光谱脑肿瘤分割网络结构图;

[0048] 图5为本发明实施例原型注意力模块的结构图;

- [0049] 图6为本发明实施例空间感知的前馈网络模块图；
- [0050] 图7为本发明实施例实验结果示例图。

具体实施方式

[0051] 为使本发明的目的、技术方案及优点更加清楚明白,以下根据附图并列举实施例,对本发明做进一步详细说明。

[0052] 如图4所示,本发明提供一种基于原型注意力网络的高光谱脑肿瘤手术引导分割方法,包括以下步骤:

[0053] 步骤1:通过术中高光谱成像平台,获取脑肿瘤的高光谱图像数据,并构建用于训练的标准数据集;

[0054] 步骤2:设计并构建基于原型注意力网络的高光谱图像分割模型,该模型通过自适应聚焦重要特征,增强肿瘤与正常组织之间的差异性;

[0055] 步骤3:使用高光谱脑肿瘤训练数据集对模型进行训练,优化网络参数,以提高分割精度和实时性能;

[0056] 步骤4:将训练好的模型部署于高光谱图像采集平台,实时处理采集到的脑肿瘤高光谱图像,输出分割结果并生成手术引导信息。

[0057] 所述步骤1包括以下子步骤:

[0058] 步骤1.1:通过高光谱采集平台采集高质量的术中高光谱图像,同时获取对应的组织样本和病理“金标准”诊断结果,以确保数据集标注的准确性;

[0059] 步骤1.2:利用病理“金标准”诊断结果对高光谱图像进行标注,针对离体的脑肿瘤组织进行标注,确定肿瘤的不同类别及其边界;

[0060] 步骤1.3:为验证算法的有效性和模型的泛化能力,对标准数据集进行随机划分,将80%的高光谱数据作为训练数据,10%作为验证数据,10%作为测试数据,确保评估的全面性;

[0061] 步骤1.4:将高光谱图像数据与对应的类别数据整理,进行标准化处理,以形成脑肿瘤分割的标准训练数据集。

[0062] 所述步骤2包括如下子步骤:

[0063] 步骤2.1:设计原型注意力网络模型,结合原型学习和注意力机制,通过聚合相似特征来增强肿瘤特征的表示能力;

[0064] 步骤2.2:根据脑肿瘤分割的训练数据集,设置网络的输入和输出大小,配置所需的参数值,包括学习率、优化器函数和损失函数等。

[0065] 所述步骤3包括如下子步骤:

[0066] 步骤3.1:设置原型注意力网络的训练轮数,以确保模型充分学习和损失收敛;

[0067] 步骤3.2:将高光谱图像训练数据集输入到步骤2构建的网络中进行训练,网络在训练过程中不断调整参数以提高分割效果;

[0068] 步骤3.3:训练完成后,保存优化后的网络参数和权重文件,以便后续使用。

[0069] 所述步骤4包括如下子步骤:

[0070] 步骤4.1:部署在高光谱标准采集平台上,完成近实时分割;

[0071] 步骤4.2:获取待分割的术中高光谱图像,确保采集方式和仪器与训练数据一致;

[0072] 步骤4.3:对待分类的高光谱图像进行处理,以符合网络输入要求;
 [0073] 步骤4.4:将处理后的高光谱图像输入至训练好的原型注意力网络;
 [0074] 步骤4.5:获得高光谱图像全图的分割结果,识别出脑肿瘤类型,并生成分割报告,为医生提供术中决策支持。

[0075] 以下是根据上述高光谱脑肿瘤手术引导分割方法进行的实例流程:

[0076] 1.数据准备与预处理:

[0077] 如图1所示,将脑肿瘤手术引导过程中采集的高光谱图像数据进行预处理。为确保数据的一致性,利用标准反射板对光谱数据进行校正。光谱范围为400-1000nm,包含128个波段,空间分辨率为 512×512 。经过处理后,数据标准化并生成适合深度学习训练的图像数据集。

[0078] 2.构建基于原型注意力的高光谱脑肿瘤分割网络:

[0079] 如图2所示,搭建基于原型注意力的高光谱脑肿瘤分割网络模型,整个网络分为五个模块:

[0080] 第一模块:图块嵌入模块

[0081] 图块嵌入模块用于提取高光谱图块的空谱联合嵌入特征,卷积核大小为 $64 \times 4 \times 4$,步幅为4,得到 $64 \times 128 \times 128$ 的特征图:

[0082] $X = \text{conv}(I_{in})$

[0083] 第二模块:原型注意力模块

[0084] 如图5所示,构建原型注意力模块,通过对高光谱图像中各像素间的特征关系进行建模来捕捉空谱信息。引入可学习的原型 $Z \in R^{n \times d}$,其中n表示原型的数量。原型的键 $K_c \in R^{N \times d}$ 和值 $V_c \in R^{N \times d}$ 分别为

[0085] $K_c = \text{softmax}(ZX^T, \text{dim}=0)K$

[0086] $V_c = \text{softmax}(ZX^T, \text{dim}=0)V$

[0087] 其中,表达式 $\text{softmax}(ZX^T, \text{dim}=0)$ 计算了高光谱图像中所有特征的相似度分数。该过程与用于更新原型的soft K-means算法类似。随后,原型注意力结果如下:

$$[0088] C(Q, K_c, V_c) = \text{softmax}\left(\frac{QK_c^T}{\sqrt{d}}, \text{dim}=1\right)V_c$$

[0089] 上述为单个原型注意力的计算过程。在自注意模块中,与单头自注意力相比,多头自注意力通过使各个标记能够捕捉到超出其单一上下文的信息,表现出更优越的性能,从而有效缓解了过拟合现象。这一概念符合“不要将所有资源集中在一个区域”的原则,强调多样化特征提取的重要性,以生成更具鲁棒性的表示。同样地,我们在方法中引入了多头原型注意力,设头的数量为h。因此,Q、K和V通常在通道维度上划分,每个部分位于 $R^{N \times (d/h)}$ 中。为了进一步增强原型注意力的多样性,我们沿着第一维度划分Z,得到

$Z^1 \in R^{n_1 \times d}, Z^2 \in R^{n_2 \times d}, \dots, Z^h \in R^{n_h \times d}$ 。接着,我们对第i个头($1 \leq i \leq h$)将 Q^i, K^i, V^i 应用到上述原型注意力计算。所有头的输出随后连接在一起以生成最终输出。

[0090] 第三模块:空间感知前馈网络模块

[0091] 如图6所示,空间感知前馈网络模块包含多尺度深度可分离卷积和前馈网络模型。首先在对输入的特征在通道进行特征划分,然后分别利用不同核大小的深度可分离卷积进

行计算：

[0092] $I_1 = \text{depthconv}(I_{i1})$

[0093] $I_2 = \text{depthconv}(I_{i2})$

[0094] $I_3 = \text{depthconv}(I_{i3})$

[0095] 接着，将不同输出合并为 $I = (I_1, I_2, I_3)$ ，并将其输入至前馈网络：

[0096] $\text{out} = \text{FC}_2(\text{ReLU}(\text{FC}_1(I)))$

[0097] 其中FC为连接层，ReLU为线性整流激活函数。通过将深度可分离卷积层置于前部，并使用不同的卷积核大小提升模型的灵活性。对于具有更多原型的头，使用更大卷积核，而原型较少的头使用较小卷积核，以平衡局部和全局特征信息。

[0098] 在基于原型注意力的高光谱脑肿瘤分割网络中，第二和第三模块连接成一个新的模块，并且重复该模块L次。

[0099] 第四模块：分类模块

[0100] 在多层原型注意力和空间感知前馈网络模型提出的特征基础上，利用两个全连接层，即投影层和线性分类层，得到最终的分割图输出(图7)：

[0101] $\text{Class} = \text{FC}_4((\text{FC}_3(I)))$

[0102] 模型训练与部署：

[0103] 如图3所示，训练步骤包括以下几方面：

[0104] 首先，将标准化后的高光谱图像数据集输入模型，采用优化损失函数、梯度计算及迭代优化来改进模型性能，最终保存模型参数。然后，利用训练好的模型在测试数据集上进行验证。最后，将模型部署至临床系统中，实时指导脑肿瘤的切除手术。

[0105] 上述根据本发明的方法可在硬件、固件中实现，或者被实现为可存储在记录介质(诸如CD ROM、RAM、软盘、硬盘或磁光盘)中的软件或计算机代码，或者被实现通过网络下载的原始存储在远程记录介质或非暂时机器可读介质中并将被存储在本地记录介质中的计算机代码，从而在此描述的方法可被存储在使用通用计算机、专用处理器或者可编程或专用硬件(诸如ASIC或FPGA)的记录介质上的这样的软件处理。可以理解，计算机、处理器、微处理器控制器或可编程硬件包括可存储或接收软件或计算机代码的存储组件(例如，RAM、ROM、闪存等)，当所述软件或计算机代码被计算机、处理器或硬件访问且执行时，实现在此描述的高光谱脑肿瘤手术引导分割方法。此外，当通用计算机访问用于实现在此示出的处理的代码时，代码的执行将通用计算机转换为用于执行在此示出的处理的专用计算机。

[0106] 本领域的普通技术人员将会意识到，这里所述的实施例是为了帮助读者理解本发明的实施方法，应被理解为本发明的保护范围并不局限于这样的特别陈述和实施例。本领域的普通技术人员可以根据本发明公开的这些技术启示做出各种不脱离本发明实质的其它各种具体变形和组合，这些变形和组合仍然在本发明的保护范围内。

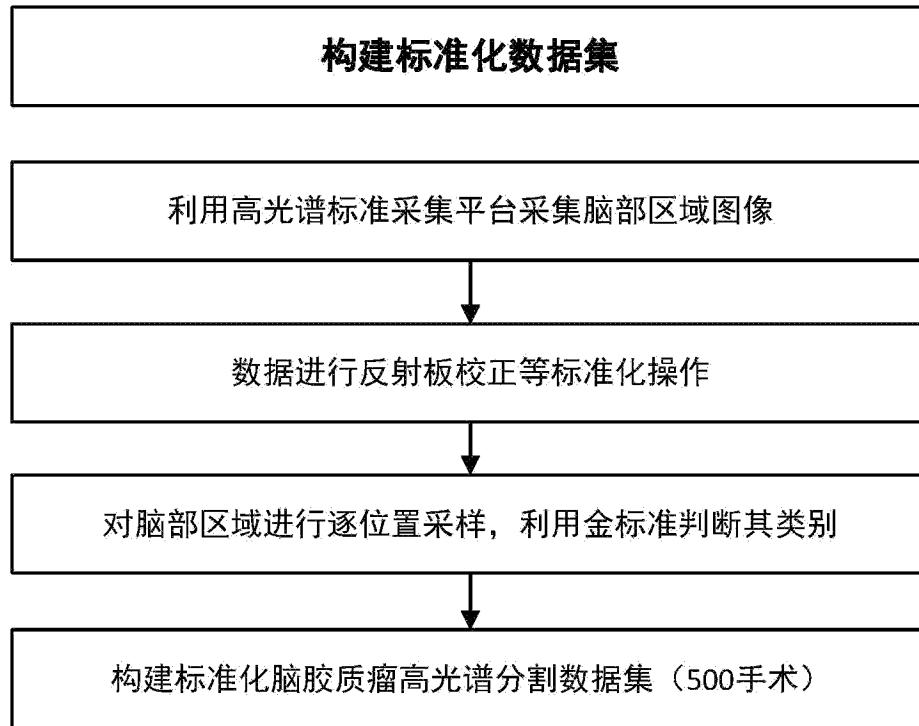


图1

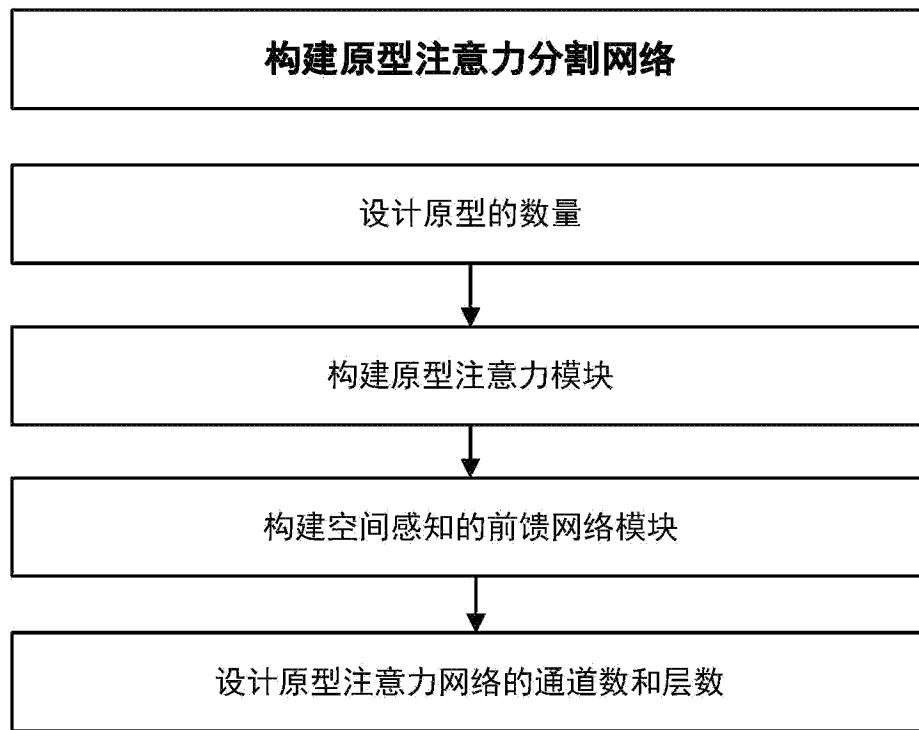


图2

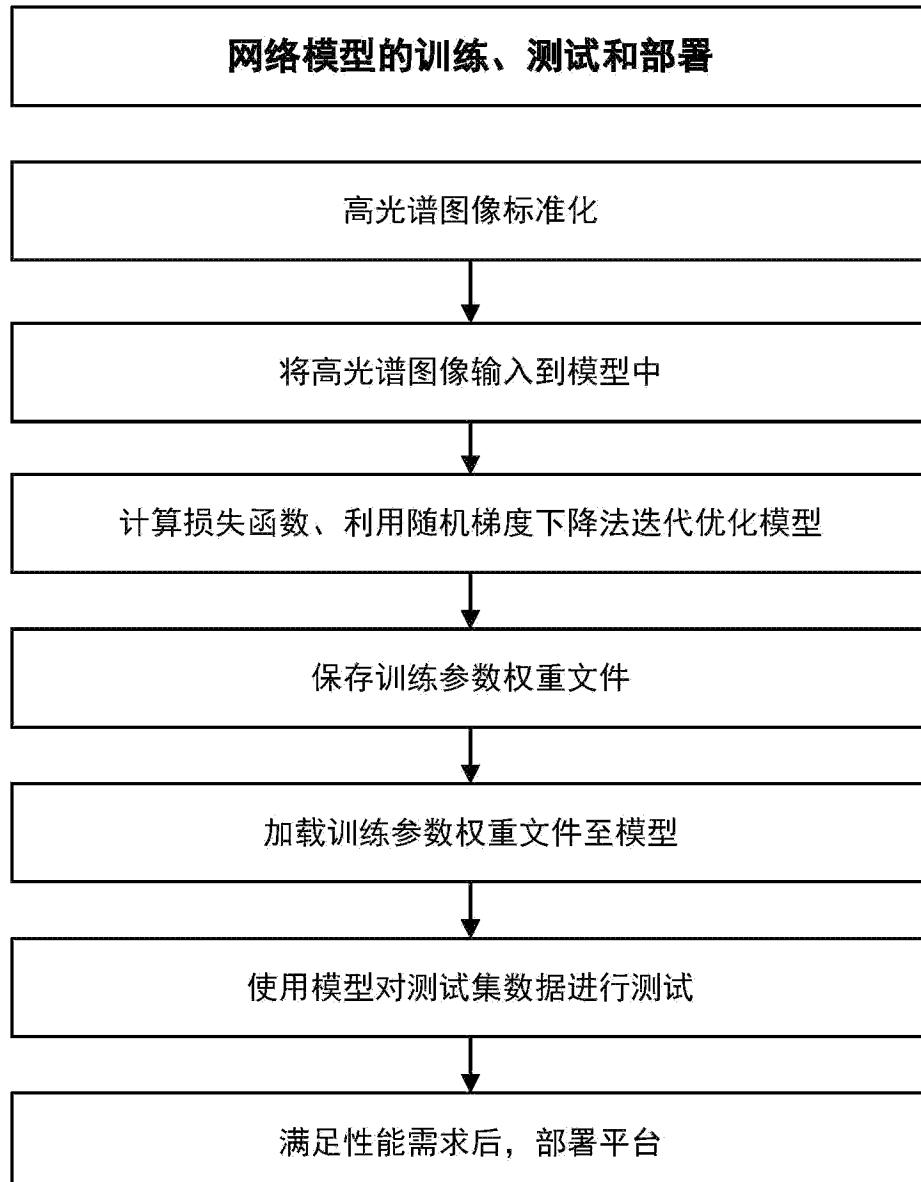


图3

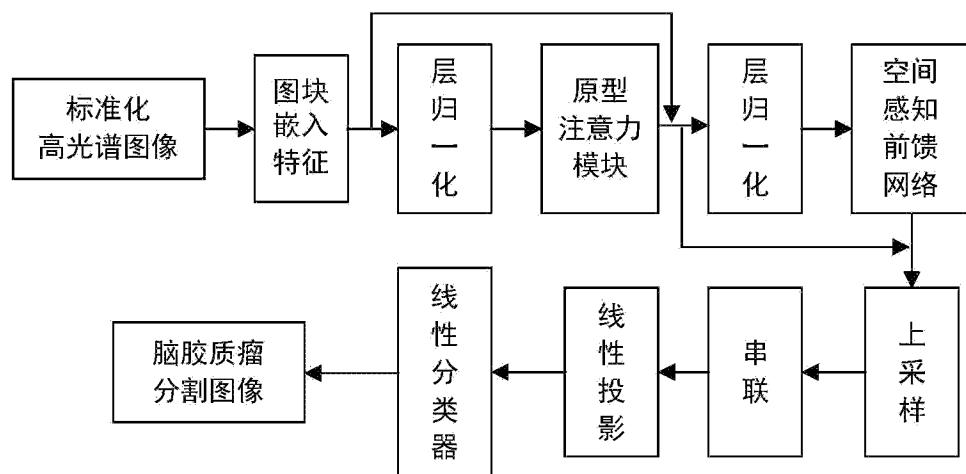


图4

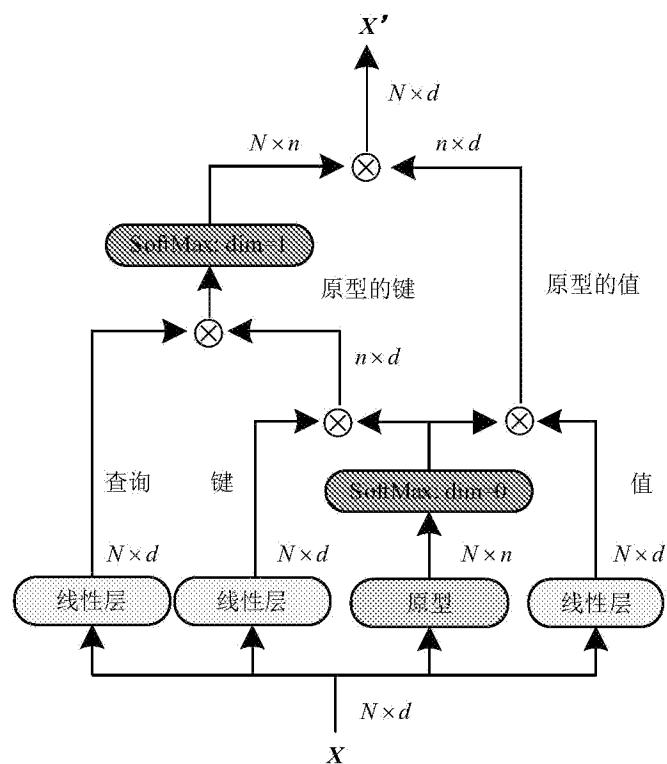


图5

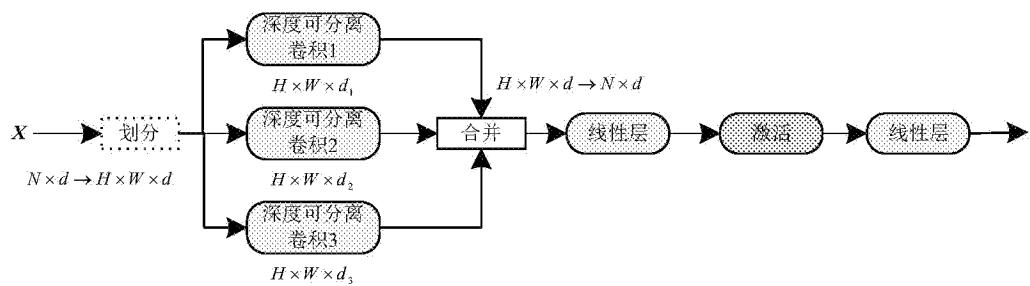


图6



图7