



(12) 发明专利申请

(10) 申请公布号 CN 115984231 A

(43) 申请公布日 2023. 04. 18

(21) 申请号 202310037801.4

G06T 7/11 (2017.01)

(22) 申请日 2023.01.10

G06V 10/774 (2022.01)

G06V 10/764 (2022.01)

(71) 申请人 厦门大学附属翔安医院

G06V 10/44 (2022.01)

地址 361000 福建省厦门市翔安区翔安南路、翔安东路交叉口东南片区

G06V 10/82 (2022.01)

申请人 厦门术利康医学科技有限公司

G06N 3/048 (2023.01)

G06N 3/08 (2023.01)

(72) 发明人 张国君 杨晨晖 白静雯 余世龙 范雪琪 黄文河 牛蕾 彭文铎

G06N 3/0464 (2023.01)

(74) 专利代理机构 厦门致群财富专利代理事务所(普通合伙) 35224

专利代理师 巫其荣

(51) Int. Cl.

G06T 7/00 (2017.01)

G06T 5/50 (2006.01)

G06T 3/40 (2006.01)

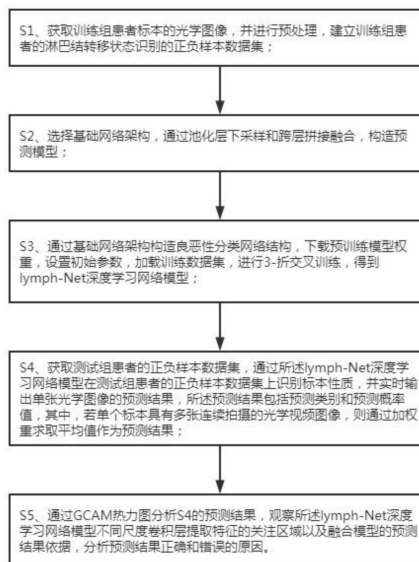
权利要求书2页 说明书7页 附图4页

(54) 发明名称

一种基于光学图像的癌症患者标本性质的辨别方法及应用

(57) 摘要

本发明公开了一种基于光学图像的癌症患者标本性质的辨别方法,包括以下步骤:S1、获取训练组患者标本的光学图像,并进行预处理,建立训练组患者的淋巴结转移状态识别的正负样本数据集;S2、选择基础网络架构,通过池化层下采样和跨层拼接融合,构造预测模型;S3、通过基础网络架构构造良恶性分类网络结构,下载训练模型权重,设置初始参数,加载训练数据集,进行3-折交叉训练,得到lymph-Net深度学习网络模型;S4、获取测试组患者的正负样本数据集,通过所述lymph-Net深度学习网络模型在测试组患者的正负样本数据集上识别标本性质;S5、通过GCAM热力图分析S4的预测结果,观察所述lymph-Net深度学习网络模型不同尺度卷积层提取特征的关注区域以及融合模型的预测结果依据,分析预测结果正确和错误的原因。



1. 一种基于光学图像的癌症患者标本性质的辨别方法,其特征在于,包括以下步骤:

S1、获取训练组患者标本的光学图像,并进行预处理,建立训练组患者的淋巴结转移状态识别的正负样本数据集;

S2、选择基础网络架构,通过池化层下采样和跨层拼接融合,构造预测模型;

S3、通过基础网络架构构造良恶性分类网络结构,下载预训练模型权重,设置初始参数,加载训练数据集,进行3-折交叉训练,得到lymph-Net深度学习网络模型;

S4、获取测试组患者的正负样本数据集,通过所述lymph-Net深度学习网络模型在测试组患者的正负样本数据集上识别标本性质,并实时输出单张光学图像的预测结果,所述预测结果包括预测类别和预测概率值,其中,若单个标本具有多张连续拍摄的光学视频图像,则通过加权重求取平均值作为预测结果;

S5、通过GCAM热力图分析S4的预测结果,观察所述lymph-Net深度学习网络模型不同尺度卷积层提取特征的关注区域以及融合模型的预测结果依据,分析预测结果正确和错误的原因。

2. 如权利要求1所述的一种基于光学图像的癌症患者标本性质的辨别方法,其特征在于,步骤S1具体为:

S11、收集训练组患者标本的光学图像和患者的病理结果;

S12、对所述光学图像进行裁剪,并去除拍摄中的冗余信息,得到训练组患者标本的多帧光学图像,并结合病例结果,构建淋巴结转移状态识别的正负样本训练数据集。

3. 如权利要求1所述的一种基于光学图像的癌症患者标本性质的辨别方法,其特征在于,步骤S2中采用ResNet-152神经网络作为前哨淋巴结转移预测模型的基础网络架构。

4. 如权利要求3所述的一种基于光学图像的癌症患者标本性质的辨别方法,其特征在于,步骤S2具体为:

S21、通过ResNet-152神经网络对训练组患者标本的光学图像进行特征提取,获取对训练组患者标本性质预测的有效特征图;

S22、提取ResNet-152神经网络中不同深度的卷积层特征向量进行拼接融合,得到多尺度融合特征;

S23、将融合特征经过平均池化层和全连接层转化为二分类结果输出,使用max函数对softmax函数的输出值进行操作,得出训练组患者的预测类别。

5. 如权利要求4所述的一种基于光学图像的癌症患者标本性质的辨别方法,其特征在于,步骤S21具体为:

S211、将训练组患者标本的光学图像输入到ResNet-152神经网络中,经过多层瓶颈层结构的卷积层和批归一化层的叠加由浅到深进行特征提取,浅层瓶颈层提取标本的形态学特征,深层瓶颈层提取标本的高级语义特征,批归一化层能够有效保证模型的正则化,缓解梯度消失问题,最后一层卷积层输出完整的特征图;

S212、最后一层卷积层后衔接一层自适应平均池化层对所有特征图中的特征进行选择,求取各个特征图的平均值作为有效特征;

S213、将各个特征图中的有效特征分别在浅层特征图和深层特征图中进行适当的选择拼接融合,形成对训练组患者标本性质预测的有效特征图。

6. 如权利要求4所述的一种基于光学图像的癌症患者标本性质的辨别方法,其特征在

于,步骤S22具体为:

S221、将训练组患者标本性质预测的有效特征图分别在ResNet-152神经网络深度为[33,115,477,509]的卷积层卷积后提取待融合特征图;

S222、浅层特征经过自适应平均池化层对待融合特征图大小进行调整,然后将4个尺度上的待融合特征图进行拼接融合,得到3840个融合特征图,其中,浅层卷积层和深层卷积层对结果预测占有相同的权重系数。

7.如权利要求1所述的一种基于光学图像的癌症患者标本性质的辨别方法,其特征在于,步骤S3具体为:

S31、通过resnet-152神经网络构造良恶性分类网络结构,加载resnet-152神经网络在训练组患者的正负样本训练数据集上的预训练权重来初始化预测模型;

S32、采用3-折交叉验证的方式将训练组患者的正负样本数据集按照7:3的比例随机划分为训练数据集和验证数据集,先使用小规模训练数据集预训练模型,微调模型参数,然后再使用大批量训练数据集训练模型,加速模型参数收敛,得到lymph-Net深度学习网络模型;

S33、采用lymph-Net深度学习网络模型对验证数据集进行训练测试,构建混淆矩阵和ROC曲线,收集每一轮训练和测试的loss值、准确率、精确率、召回率及F1得分,并制作相应可视化曲线,验证lymph-Net深度学习网络模型的模型稳定性。

8.如权利要求1所述的一种基于光学图像的癌症患者标本性质的辨别方法,其特征在于,步骤S4具体为:

S41、获取测试组患者标本的光学图像,进行形状归一化和中心裁剪预处理,建立测试组患者的淋巴结转移状态识别的正负样本数据集,并定义阴性标签为1,阳性标签为0;

S42、加载3-折交叉验证后得到的lymph-Net深度学习网络模型权重,并在测试组患者的淋巴结转移状态识别的正负样本数据集进行模型验证,分别输出单张图像的预测类别和预测概率值;

S43、根据测试组患者单个标本在光学图像视频中出现的连续帧,每个标本的阴阳性概率由标本出现所有帧的阴阳性概率的所有值进行加权平均,根据单张图像在单个标本光学图像集中所占比例设置权重系数,将预测概率值乘上权重系数作为单张图像预测比重,单个标本图像集所有比重求和作为最终预测结果。

9.一种权利要求1所述的基于光学图像的癌症患者标本性质的实时辨别方法应用于术中实时鉴别癌症患者标本性质、手术切缘性质、肿瘤边界、区分癌症患者区域淋巴结转移状态及辨别患者癌灶的基因组信息。

一种基于光学图像的癌症患者标本性质的辨别方法及应用

技术领域

[0001] 本发明涉及视频图像处理技术领域,具体涉及一种基于光学图像的癌症患者标本性质的辨别方法及应用。

背景技术

[0002] 癌症作为全球高发疾病,严重影响患者的身心健康。在多种癌症中均存在外科医生在术中难以分辨肿瘤的边界,导致手术切缘仍有手术残留,进而导致早期复发的的问题。因此,在手术过程中对标本进行快速、准确的诊断至关重要。癌灶的遗传信息可以用于确定预后并且指导治疗。此外,淋巴转移是癌症恶性演进的重要途径。淋巴结转移的识别对于实体瘤的分期至关重要,是重要的预后影响因素。完整的淋巴结清扫术,在诸多癌症中被证明对患者的准确分期是重要的。

[0003] 然而,在早期胃癌和早期乳腺癌等癌症中患者的淋巴结转移率较低。因此造成许多淋巴结转移的患者接受了不必要的淋巴结清扫术。前哨淋巴结(SLN)是癌症患者发生淋巴结转移所必经的第一站或者第一组淋巴结,即SLN没有发生转移,理论上其他区域淋巴结是没有肿瘤转移的。乳晕或肿瘤周围注射SLN示踪剂,在腋窝部位经特殊设备探测或者可视化示踪剂的分布情况,可以识别SLN。近年来近红外荧光成像逐渐被引入手术中成为外科医生的辅助工具。目前ICG荧光成像已经用于乳腺癌、卵巢癌、消化道肿瘤、胶质瘤等多种癌种。虽然ICG荧光成像技术更直观、灵敏,且具有较高的识别率,但尚不能在肉眼水平鉴别其是否发生转移。因此,有必要探索光学图像(包括但不限于ICG荧光图像)与标本性质之间的关系。

[0004] 目前的术前影像学方法(包括超声、X射线、CT、PET-CT、MRI等),在术前鉴别患者肿物的良恶性、癌灶的基因组信息、区域淋巴结转移状况以及肿瘤边界或预测手术切缘的性质等方面表现不理想。术中对于患者手术标本(肿物/结节)、手术切缘、区域淋巴结性质的辨别依赖于术中冰冻病理结果,冰冻切片技术复杂,且耗时长(需40分钟-1小时),存在较高的假阴性率,在手术过程中冷冻10个或数百个样本是不切实际的,这限制了肿瘤术中实时诊断的发展,特别是对于多个组织样本。另外在手术期间对肿瘤组织的分级和基因组水平信息的获取是不可能的。术后获取病理结果是患者手术标本(肿物/结节)、肿瘤边界或手术切缘、区域淋巴结性质以及基因组信息鉴定的金标准,但这种技术是耗时的,受到观察者间高度变异性的影响,并且检查大量的标本(肿物/结节/淋巴结)会导致劳动力、空间以及设备和用品的使用超负荷,增加医疗保健的成本。

发明内容

[0005] 本发明提出一种基于光学图像的癌症患者标本性质的辨别方法及应用用于解决上述问题。

[0006] 为实现上述目的,本发明采用以下技术方案:

[0007] 一种基于光学图像的癌症患者标本性质的辨别方法,包括以下步骤:

[0008] S1、获取训练组患者标本的光学图像,并进行预处理,建立训练组患者的淋巴结转移状态识别的正负样本数据集;

[0009] S2、选择基础网络架构,通过池化层下采样和跨层拼接融合,构造预测模型;

[0010] S3、通过基础网络架构构造良恶性分类网络结构,下载预训练模型权重,设置初始参数,加载训练数据集,进行3-折交叉训练,得到lymph-Net深度学习网络模型;

[0011] S4、获取测试组患者的正负样本数据集,通过所述lymph-Net深度学习网络模型在测试组患者的正负样本数据集上识别标本性质,并实时输出单张光学图像的预测结果,所述预测结果包括预测类别和预测概率值,其中,若单个标本具有多张连续拍摄的光学视频图像,则通过加权重求取平均值作为预测结果;

[0012] S5、通过GCAM热力图分析S4的预测结果,观察所述lymph-Net深度学习网络模型不同尺度卷积层提取特征的关注区域以及融合模型的预测结果依据,分析预测结果正确和错误的原因。

[0013] 优选地,步骤S1具体为:

[0014] S11、收集训练组患者标本的光学图像和患者的病理结果;

[0015] S12、对所述光学图像进行裁剪,并去除拍摄中的冗余信息,得到训练组患者标本的多帧光学图像,并结合病例结果,构建淋巴结转移状态识别的正负样本训练数据集。

[0016] 优选地,其特征不在于,步骤S2中采用ResNet-152神经网络作为前哨淋巴结转移预测模型的基础网络架构。

[0017] 优选地,步骤S2具体为:

[0018] S21、通过ResNet-152神经网络对训练组患者标本的光学图像进行特征提取,获取对训练组患者标本性质预测的有效特征图;

[0019] S22、提取ResNet-152神经网络中不同深度的卷积层特征向量进行拼接融合,得到多尺度融合特征;

[0020] S23、将融合特征经过平均池化层和全连接层转化为二分类结果输出,使用max函数对softmax函数的输出值进行操作,得出训练组患者的预测类别。

[0021] 优选地,步骤S21具体为:

[0022] S211、将训练组患者标本的光学图像输入到ResNet-152神经网络中,经过多层瓶颈层结构的卷积层和批归一化层的叠加由浅到深进行特征提取,浅层瓶颈层提取标本的形态学特征,深层瓶颈层提取标本的高级语义特征,批归一化层能够有效保证模型的正则化,缓解梯度消失问题,最后一层卷积层输出完整的特征图;

[0023] S212、最后一层卷积层后衔接一层自适应平均池化层对所有特征图中的特征进行选择,求取各个特征图的平均值作为有效特征;

[0024] S213、将各个特征图中的有效特征分别在浅层特征图和深层特征图中进行适当的选择拼接融合,形成对训练组患者标本性质预测的有效特征图。

[0025] 优选地,步骤S22具体为:

[0026] S221、将训练组患者标本性质预测的有效特征图分别在ResNet-152神经网络深度为[33,115,477,509]的卷积层卷积后提取待融合特征图;

[0027] S222、浅层特征经过自适应平均池化层对待融合特征图大小进行调整,然后将4个尺度上的待融合特征图进行拼接融合,得到3840个融合特征图,其中,浅层卷积层和深层卷

积层对结果预测占有相同的权重系数。

[0028] 优选地,步骤S3具体为:

[0029] S31、通过resnet-152神经网络构造良恶性分类网络结构,加载resnet-152神经网络在训练组患者的正负样本训练数据集上的预训练权重来初始化预测模型;

[0030] S32、采用3-折交叉验证的方式将训练组患者的正负样本数据集按照7:3的比例随机划分为训练数据集和验证数据集,先使用小规模训练数据集预训练模型,微调模型参数,然后再使用大批量训练数据集训练模型,加速模型参数收敛,得到lymph-Net深度学习网络模型;

[0031] S33、采用lymph-Net深度学习网络模型对验证数据集进行训练测试,构建混淆矩阵和ROC曲线,收集每一轮训练和测试的loss值、准确率、精确率、召回率及F1得分,并制作相应可视化曲线,验证lymph-Net深度学习网络模型的模型稳定性。

[0032] 优选地,步骤S4具体为:

[0033] S41、获取测试组患者标本的光学图像,进行形状归一化和中心裁剪预处理,建立测试组患者的淋巴结转移状态识别的正负样本数据集,并定义阴性标签为1,阳性标签为0;

[0034] S42、加载3-折交叉验证后得到的lymph-Net深度学习网络模型权重,并在测试组患者的淋巴结转移状态识别的正负样本数据集进行模型验证,分别输出单张图像的预测类别和预测概率值;

[0035] S43、根据测试组患者单个标本在光学图像视频中出现的连续帧,每个标本的阴阳性概率由标本出现所有帧的阴阳性概率的所有值进行加权平均,根据单张图像在单个标本光学图像集中所占比例设置权重系数,将预测概率值乘上权重系数作为单张图像预测比重,单个标本图像集所有比重求和作为最终预测结果。

[0036] 一种基于光学图像的癌症患者标本性质的辨别方法应用于实时术中鉴别癌症患者标本性质、手术切缘性质、肿瘤边界、区分癌症患者区域淋巴结转移状态及辨别患者癌灶的基因组信息。

[0037] 采用上述技术方案后,本发明与背景技术相比,具有如下优点:

[0038] 1、本发明提供一种基于光学图像的癌症患者标本性质的辨别方法及应用,通过建立lymph-Net深度学习网络模型,可以在自动捕获手术标本(肿物/结节)、肿瘤边界/手术切缘、区域淋巴结的光学图像分析该图像的特征,提供准确的实时视觉信息,有助于外科医生鉴别患者标本性质、手术切缘性质、肿瘤边界、区分癌症患者区域淋巴结转移状态,以及辨别患者癌灶的基因组信息方面具有较高的临床应用价值,在术中快速给出与病理信息相匹配的判定结果,实时、快速、高灵敏、高特异性报告癌症患者标本性质,指导外科医生在术中进行快速而完善的手术决策,并且减少术后并发症,降低患者手术风险,节省患者医疗负担,减轻医生繁杂的工作量,为患者的有效治疗决策和精准分期提供保障。

[0039] 2、本发明提供一种基于光学图像的癌症患者标本性质的辨别方法及应用,lymph-Net深度学习网络模型适用于不同的荧光染料和不同光学设备的光学图像,有效应用于乳腺癌患者、妇科癌症患者、卵巢癌患者、脑肿瘤患者、消化系统肿瘤患者胃癌患者、肝癌患者等、以及头颈部鳞状细胞癌等多种实体瘤患者。

附图说明

- [0040] 图1为本发明方法步骤流程图；
[0041] 图2为本发明网络架构示意图；
[0042] 图3为本发明术中荧光视频采集过程图；
[0043] 图4为本发明网络结构；
[0044] 图5为本发明卷积层多尺度特征融合过程示意图；
[0045] 图6为本发明模型的二种不同方式热图；
[0046] 图7为本发明模型效果热图；
[0047] 图8为本发明模型(Lymph-Net)AUC结果展示。

具体实施方式

[0048] 为了使本发明的目的、技术方案及优点更加清楚明白，以下结合附图及实施例，对本发明进行进一步详细说明。应当理解，此处所描述的具体实施例仅仅用以解释本发明，并不用于限定本发明。

[0049] 实施例

[0050] 配合图1至图7所示，本发明公开了一种基于光学图像的癌症患者标本性质的辨别方法，包括以下步骤：

[0051] S1、获取训练组患者标本的光学图像(本实施例中光学图像采用荧光动态视频图像，但在实际应用中不局限于荧光动态视频图像)，并进行预处理，建立训练组患者的淋巴结转移状态识别的正负样本数据集；

[0052] 步骤S1具体为：

[0053] S11、以病例为单位，对训练组患者注射示踪剂，术中剥离标本表面脂肪，收集训练组患者标本的离体NI区光学图像和患者的病理结果；

[0054] 具体为：使用DPM H2000荧光内窥镜摄像系统，对训练组患者进行注射相同剂量的示踪剂(亚甲蓝配置浓度为10mg/mL原液，取1mL原液，用生理盐水稀释至2mL，稀释终浓度为5mg/mL。另外，将25mg ICG与10mL生理盐水配置成2.5mg/mL ICG原液，取1mL ICG原液，用生理盐水稀释至2mL，稀释终浓度为1.25mg/mL)。每位患者注射示踪剂后进行在体成像，然后由对外科医生对离体的标本进行辨别和分离，剥离其表面纤维脂肪组织，在送病理科行术中冰冻切片病理检查前，使用DPM H2000荧光内窥镜摄像系统对所有送检的标本在暗箱中进行视频录制，获取训练组患者标本的离体NI区光学图像。

[0055] 本实施例中光学图像采用标准为：

[0056] 使用DPM H2000荧光内窥镜摄像一体机系统具有全高清视频输出： $\geq 1920 \times 1080P$ ，宽高比为16:9，晶片为4*1/3inch，荧光灵敏度： $0.305 \mu\text{g}/\text{mL}$ ，设备功率：150VA、曝光时间20ms。在每次成像前对成像系统进行白平衡校准。

[0057] 图像标准：成像距离1cm、以镜头干净、图像清晰，对焦合适为基准。

[0058] 格式：从DPM导出的无压缩TS-MPEG2 Transport(.ts)格式动态视频图像。

[0059] S12、对光学图像进行裁剪，并去除拍摄中的冗余信息，得到训练组患者标本的多帧光学图像，并结合病例结果，构建淋巴结转移状态识别的正负样本训练数据集。

[0060] S2、选择基础网络架构，通过池化层下采样和跨层拼接融合，构造预测模型；

[0061] 步骤S2中采用ResNet-152神经网络作为前哨淋巴结转移预测模型的基础网络架构。

[0062] 首先选取vgg、densenet、efficientnet、resnet4种不同的基础神经网络模型,分别在样本数据集上进行初筛;综合对比4种基础神经网络的准确率、处理速率及loss值大小性能,最终选取ResNet-152神经网络作为前哨淋巴结转移预测模型的基础网络架构,在resnet-152网络的conv2_x层、conv3_x层、conv4_x层、conv5_x层分别截取特征图,通过自适应平均池化层分别对特征图下采样,特征图大小分别为原来的1/8,1/4,1/2;将4个尺度的特征图进行拼接融合,作为网络的最终输出;

[0063] 修改ResNet-152神经网络最后一层的全连接层输出维度为2,对应淋巴结转移的阴性和阳性,使用交叉熵损失作为损失函数,使用随机梯度下降法来调整每一轮的网络参数,设置初始学习率,权值衰减系数,防止过拟合。

[0064] 步骤S2具体为:

[0065] S21、通过ResNet-152神经网络对训练组患者标本的光学图像进行特征提取,获取对训练组患者标本性质预测的有效特征图;

[0066] 步骤S21具体为:

[0067] S211、将训练组患者标本的光学图像输入到ResNet-152神经网络中,经过多层瓶颈层结构的卷积层和批归一化层的叠加由浅到深进行特征提取,浅层瓶颈层提取标本的形态学特征,深层瓶颈层提取标本的高级语义特征,批归一化层能够有效保证模型的正则化,缓解梯度消失问题,最后一层卷积层输出完整的特征图;

[0068] S212、最后一层卷积层后衔接一层自适应平均池化层对所有特征图中的特征进行选择,求取各个特征图的平均值作为有效特征;

[0069] S213、将各个特征图中的有效特征分别在浅层特征图和深层特征图中进行适当的选择拼接融合,形成对训练组患者标本性质预测的有效特征图。

[0070] S22、提取ResNet-152神经网络中不同深度的卷积层特征向量进行拼接融合,得到多尺度融合特征;

[0071] 步骤S22具体为:

[0072] S221、将训练组患者标本性质预测的有效特征图分别在ResNet-152神经网络深度为[33,115,477,509]的卷积层卷积后提取待融合特征图;

[0073] S222、浅层特征经过自适应平均池化层对待融合特征图大小进行调整,然后将4个尺度上的待融合特征图进行拼接融合,得到3840个融合特征图,其中,浅层卷积层和深层卷积层对结果预测占有相同的权重系数。同时,自适应平均池化可以对空间维度进行压缩,同时取出对应维度的均值,在一定程度上可以抑制一些没用的特征。

[0074] S23、将融合特征经过平均池化层和全连接层转化为二分类结果输出,使用max函数对softmax函数的输出值进行操作,得出训练组患者的预测类别。

[0075] S3、通过基础网络架构构造良恶性分类网络结构,下载预训练模型权重,设置初始参数,加载训练数据集,进行3-折交叉训练,得到lymph-Net深度学习网络模型;

[0076] 步骤S3具体为:

[0077] S31、通过resnet-152神经网络构造良恶性分类网络结构,加载resnet-152神经网络在训练组患者的正负样本训练数据集上的预训练权重来初始化预测模型;

[0078] S32、采用3-折交叉验证的方式将训练组患者的正负样本数据集按照7:3的比例随机划分为训练数据集和验证数据集,先使用小规模训练数据集预训练模型,微调模型参数,然后再使用大批量训练数据集训练模型,加速模型参数收敛,得到lymph-Net深度学习网络模型;

[0079] 训练数据集每次训练时在 256×256 的图像内随机选取 224×224 图像块,对于选取的图像块随机设置旋转角度,并以一定的概率随机增强饱和度、对比度和亮度,每一轮迭代后自适应调整学习率和学习衰减策略。

[0080] S33、采用lymph-Net深度学习网络模型对验证数据集进行训练测试,并根据样本种类、数量及数据集大小调整模型的训练频率,减少迭代次数,在所有迭代次数完成后在测试集上进行预测并构建混淆矩阵和ROC曲线,收集每一轮训练和测试的loss值、准确率、精确率、召回率及F1得分,并制作相应可视化曲线,并将上述数据相关指标作为分类器的性能标准,验证lymph-Net深度学习网络模型的模型稳定性。

[0081] S4、获取测试组患者的正负样本数据集,通过lymph-Net深度学习网络模型在测试组患者的正负样本数据集上识别标本性质,并实时输出单张光学图像的预测结果,预测结果包括预测类别和预测概率值,其中,若单个标本具有多张连续拍摄的光学视频图像,则通过加权重求取平均值作为预测结果;

[0082] 步骤S4具体为:

[0083] S41、获取测试组患者标本的光学图像,进行形状归一化和中心裁剪预处理,建立测试组患者的淋巴结转移状态识别的正负样本数据集,并定义阴性标签为1,阳性标签为0;

[0084] S42、加载3-折交叉验证后得到的lymph-Net深度学习网络模型权重,并在测试组患者的淋巴结转移状态识别的正负样本数据集进行模型验证,分别输出单张图像的预测类别和预测概率值;

[0085] S43、根据测试组患者单个标本在光学图像视频中出现的连续帧,每个标本的阴阳性概率由标本出现所有帧的阴阳性概率的所有值进行加权平均,根据单张图像在单个标本光学图像集中所占比例设置权重系数,将预测概率值乘上权重系数作为单张图像预测比重,单个标本图像集所有比重求和作为最终预测结果。

[0086] S5、通过GCAM热力图分析S4的预测结果,观察lymph-Net深度学习网络模型不同尺度卷积层提取特征的关注区域以及融合模型的预测结果依据,分析预测结果正确和错误的原因。

[0087] GCAM热力图可以以权重的形式来展现神经网络对图像的激活值分布区域,展示模型的可解释性,对于预测lymph-Net深度学习网络模型的性能,需要关注提取特征的有效性,热力图展示对于模型预测有效的部分呈现红色,而对于预测占比不高的部分呈现蓝色。

[0088] 使用两种不同的热力图可视化方式对lymph-Net深度学习网络模型的可解释性进行展示,GCAM热力图展示了对模型预测的有效区域,GCAM可以定位相关的图像区域,但是缺乏突出显示细微细节的能力.Guided Backpropagation可视化相对于图像的梯度,其中通过ReLU层反向传播可抑制负梯度,将GCAM和Guided Backpropagation可视化结合可以实现预测关注区域和图像纹理细节可视化效果的融合。

[0089] 本发明还公开一种基于光学图像的癌症患者标本性质的辨别方法应用于实时术中鉴别癌症患者标本性质、手术切缘性质、肿瘤边界、区分癌症患者区域淋巴结转移状态及

辨别患者癌灶的基因组信息。

[0090] 本实施例中光学图像采用标准为：

[0091] 使用DPM H2000荧光内窥镜摄像一体机系统具有全高清视频输出： $\geq 1920 \times 1080P$ ，宽高比为16:9，晶片为4*1/3inch，荧光灵敏度：0.305ug/mL，设备功率：150VA、曝光时间20ms。在每次成像前对成像系统进行白平衡校准。

[0092] 图像标准：成像距离1cm、以镜头干净、图像清晰，对焦合适为基准。

[0093] 格式：从DPM导出的无压缩TS-MPEG2 Transport (.ts)格式动态视频图像。

[0094] 本实施例采用上述方法后，对标本进行预测，预测结果如下表1所述：

[0095] 表1本实施例对标本的预测结果

	ACC	Precision	Recall	F1	AUC
[0096] MODEL1	0.9927	0.9961	0.9946	0.9954	0.9992
MODEL2	0.9921	0.9977	0.9923	0.9950	0.9992
MODEL3	0.9927	0.9969	0.9938	0.9954	0.9996
MODEL4	0.9915	0.9954	0.9938	0.9946	0.9991
MODEL5	0.9951	0.9961	0.9977	0.9969	0.9997

[0097] 由表1可知，本实施例方法对标本性质的鉴定结果准确率达到0.99以上，预测值（精确度）为0.9961。召回率为0.9961，较高召回率说明模型对于阳性样本检出率较高，表明该模型可以有效在不同性质的标本中做出区分，且通过该模型可以明显区分特征的差异性。

[0098] 通过不同GCAM热力图，可直观说明了我们本实施例的模型效果。GCAM与特定输出类别相关的二维特征分数网络，网格的每个位置表示该类别的重要程度。对于一张输入到Lymphnet的标本荧光图像图片，该技术可以以热力图形式呈现图片中每个位置与标本特征的相关程度，有助于了解一张原始图像的哪一个局部位置让Lymphnet模型做出了最终的分类决策。

[0099] 如图7所示，GCAM热力图在本实施例的标本荧光图像分析中，荧光图有颜色的就是GCAM部分，不同颜色表示这个模型在关注这张图的不同部位，是以这些部位为依据做出的判断，相当于对模型的一种解释，颜色深浅代表我们关注的强弱。

[0100] 以上所述，仅为本发明较佳的具体实施方式，但本发明的保护范围并不局限于此，任何熟悉本技术领域的技术人员在本发明揭露的技术范围内，可轻易想到的变化或替换，都应涵盖在本发明的保护范围之内。因此，本发明的保护范围应该以权利要求的保护范围为准。

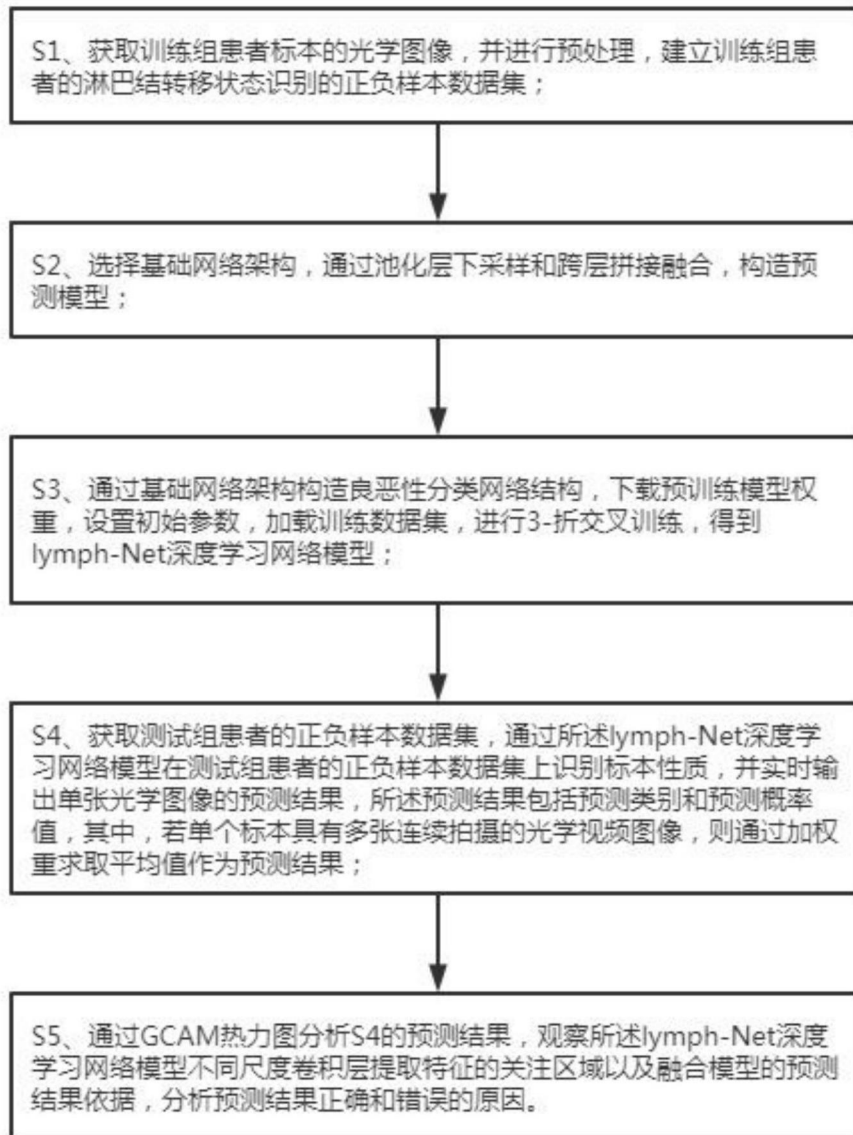


图1




图2




图3

layer name	output size	18-layer	34-layer	50-layer	101-layer	152-layer
conv1	112×112	7×7, 64, stride 2				
conv2_x	56×56	3×3 max pool, stride 2				
		$\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$
conv3_x	28×28	$\begin{bmatrix} 3 \times 3, 128 \\ 3 \times 3, 128 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 128 \\ 3 \times 3, 128 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 8$
conv4_x	14×14	$\begin{bmatrix} 3 \times 3, 256 \\ 3 \times 3, 256 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 256 \\ 3 \times 3, 256 \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 23$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 36$
conv5_x	7×7	$\begin{bmatrix} 3 \times 3, 512 \\ 3 \times 3, 512 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 512 \\ 3 \times 3, 512 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$
	1×1	average pool, 1000-d fc, softmax				
FLOPs		1.8×10^9	3.6×10^9	3.8×10^9	7.6×10^9	11.3×10^9

图4




图5




图6




图7




图8