



(12) 发明专利

(10) 授权公告号 CN 117689625 B

(45) 授权公告日 2024. 07. 23

(21) 申请号 202311626792.9

(22) 申请日 2023.11.30

(65) 同一申请的已公布的文献号

申请公布号 CN 117689625 A

(43) 申请公布日 2024.03.12

(73) 专利权人 人工智能与数字经济广东省实验室(广州)

地址 510330 广东省广州市海珠区新港东路2429号首层自编051房

专利权人 华南理工大学

(72) 发明人 胡滨 关治洪 单梁

(74) 专利代理机构 广州科粤专利商标代理有限公司 44001

专利代理师 劳剑东

(51) Int.Cl.

G06T 7/00 (2017.01)

G06N 3/0464 (2023.01)

G06N 3/048 (2023.01)

G06V 10/764 (2022.01)

G06V 10/44 (2022.01)

G06V 10/82 (2022.01)

G06N 3/084 (2023.01)

G06T 7/11 (2017.01)

(56) 对比文件

CN 116797609 A, 2023.09.22

Liang Shan et.al.. “Detecting COVID-19 on CT Images with Impulsive-Backpropagation Neural Networks”. 《2022 34th Chinese Control and Decision Conference (CCDC)》. 2023, 第2797-2803页.

审查员 周雯


权利要求书2页 说明书12页 附图7页

(54) 发明名称

多任务混杂神经网络驱动的CT图像处理和类脑诊断系统和类脑诊断系统

(57) 摘要

本发明公开了一种多任务混杂神经网络驱动的CT图像处理和类脑诊断系统,涉及人工智能医学影像,方法包括生成混杂神经网络,输入CT图像,在每一层执行混杂脉冲-卷积计算;生成共同编码器和多任务解码器,输出多任务结果图像。系统包括处理器和存储器及显示器,存储器中存储有至少一条指令,指令由处理器加载并执行以实现如下步骤:获取CT图像;生成基于混杂神经网络建立的共同编码器,调用编码器对CT图像进行编码,生成联合特征;生成基于混杂神经网络建立的多任务解码器,调用解码器对联合特征进行分类操作和分割操作,得到多任务诊断结果。本发明可以提高CT图像的多任务诊断效率,在保证多任务精度的同时降低诊断系统的计算功耗。



1. 一种CT图像处理方法,其特征在于,包括如下步骤:

获取CT图像;

生成混杂脉冲-卷积计算层,所述混杂脉冲-卷积计算层由卷积操作和脉冲神经元级联而成,根据所述混杂脉冲-卷积计算层,生成混杂神经网络;

生成基于混杂神经网络建立的共同编码器,调用所述共同编码器对所述CT图像进行编码,生成联合特征;其中,所述共同编码器包含 N_1 个层级结构,每个层级结构由2个混杂脉冲-卷积计算层、1个池化层构成,混杂脉冲-卷积计算层由卷积操作和脉冲神经元级联而成;

生成基于混杂神经网络建立的多任务解码器,调用所述多任务解码器对所述联合特征进行分类操作和多任务分割操作;其中,所述多任务解码器包括执行所述分类操作的分类模块和执行所述分割操作的分割模块,其中,所述分类模块包括CLS模块;所述分割模块包括实现不同分割功能的par-SEG模块和inf-SEG模块,所述par-SEG模块用于实现肺实质分割,所述inf-SEG模块用于实现肺部感染区域分割,所述CLS模块是由 N_2 层全连接单元构成的分类网络,每个层级结构由脉冲神经元构成,所述par-SEG模块由混杂脉冲-卷积计算层和转置卷积层搭建而成,包含 N_1 个层级结构,每个层级结构由2个混杂脉冲-卷积层、1个转置卷积层构成,所述inf-SEG模块具有与所述par-SEG模块相似的网络结构和计算单元;

生成由所述共同编码器和所述多任务解码器串联的多任务混杂神经网络,利用所述多任务混杂神经网络,输出类脑结果图像;

还包括对所述多任务混杂神经网络的训练步骤:

生成对应于所述多任务混杂神经网络中分类模块和多任务分割模块的损失函数以及总体损失函数,将训练样本输入至所述编码器和所述解码器;

调用所述损失函数并调整所述分类模块和所述多任务分割模块的损失函数的相关参数,用于使所述共同编码器和所述多任务解码器的损失下降;

根据所述训练样本的结果图像调整的所述损失函数的相关参数并计算所述分类模块和所述多任务分割模块的损失;

根据所述损失进行基于脉冲的反向传播训练优化所述多任务混杂神经网络,训练优化直至达到预设的训练停止条件,得到最优的所述多任务混杂神经网络。

2. 根据权利要求1所述的CT图像处理方法,其特征在于,所述损失函数配置有多任务操作异质性,所述分类操作的损失函数采用MSE Loss函数;所述多任务分割操作的损失函数均采用Focal Loss函数;所述总体损失函数基于各个操作的损失函数,采用正则化加权multi-loss函数。

3. 根据权利要求1所述的CT图像处理方法,其特征在于,所述混杂神经网络配置有混杂脉冲-卷积计算层由卷积操作和脉冲神经元级联而成,脉冲神经元充当激活函数,以实现低功耗的计算。

4. 一种CT类脑诊断系统,其特征在于,包括处理器、存储器和显示器,所述存储器中存储有至少一条指令,所述指令由所述处理器加载并执行以实现如下步骤:

获取CT图像;

生成混杂脉冲-卷积计算层,所述混杂脉冲-卷积计算层由卷积操作和脉冲神经元级联而成,根据所述混杂脉冲-卷积计算层,生成混杂神经网络;

生成基于混杂神经网络建立的共同编码器,调用所述共同编码器对所述CT图像进行编码,生成联合特征;其中,所述共同编码器包含 N_1 个层级结构,每个层级结构由2个混杂脉冲-卷积计算层、1个池化层构成,混杂脉冲-卷积计算层由卷积操作和脉冲神经元级联而成;

生成基于混杂神经网络建立的多任务解码器,调用所述多任务解码器对所述联合特征进行分类操作和多任务分割操作;其中,所述多任务解码器包括执行所述分类操作的分类模块和执行所述分割操作的分割模块,其中,所述分类模块包括CLS模块;所述分割模块包括实现不同分割功能的par-SEG模块和inf-SEG模块,所述par-SEG模块用于实现肺实质分割,所述inf-SEG模块用于实现肺部感染区域分割,所述CLS模块是由 N_2 层全连接单元构成的分类网络,每个层级结构由脉冲神经元构成,所述par-SEG模块由混杂脉冲-卷积计算层和转置卷积层搭建而成,包含 N_1 个层级结构,每个层级结构由2个混杂脉冲-卷积层、1个转置卷积层构成,所述inf-SEG模块具有与所述par-SEG模块相似的网络结构和计算单元;

生成由所述共同编码器和所述多任务解码器串联的多任务混杂神经网络,利用所述多任务混杂神经网络,输出类脑结果图像;

还包括对所述多任务混杂神经网络的训练步骤:

生成对应于所述多任务混杂神经网络中分类模块和多任务分割模块的损失函数以及总体损失函数,将训练样本输入至所述编码器和所述解码器;

调用所述损失函数并调整所述分类模块和所述多任务分割模块的损失函数的相关参数,用于使所述共同编码器和所述多任务解码器的损失下降;

根据所述训练样本的结果图像调整的所述损失函数的相关参数并计算所述分类模块和所述多任务分割模块的损失;

根据所述损失进行基于脉冲的反向传播训练优化所述多任务混杂神经网络,训练优化直至达到预设的训练停止条件,得到最优的所述多任务混杂神经网络。

5. 根据权利要求4所述的CT类脑诊断系统,其特征在于,所述损失函数配置有多任务操作异质性,所述分类操作的损失函数采用MSE Loss函数;所述多任务分割操作的损失函数均采用Focal Loss函数;所述总体损失函数基于各个操作的损失函数,采用正则化加权multi-loss函数。

6. 根据权利要求4所述的CT图像处理方法,其特征在于,所述混杂神经网络配置有混杂脉冲-卷积计算层由卷积操作和脉冲神经元级联而成,脉冲神经元充当激活函数,以实现低功耗的计算。

7. 一种计算机可读存储介质,其特征在于,所述存储介质中存储有至少一条指令、至少一段程序、代码集或指令集,所述至少一条指令、所述至少一段程序、所述代码集或指令集由处理器加载并执行以实现如权利要求1至3任一所述的CT图像处理方法。

多任务混杂神经网络驱动的CT图像处理方法和类脑诊断系统

技术领域

[0001] 本发明涉及人工智能医学影像,更具体地,涉及一种多任务混杂神经网络驱动的CT图像处理方法和类脑诊断系统。

背景技术

[0002] CT(Computed Tomography,计算机断层扫描)检查涉及对人体或人体某部分,以非侵入式取得内部组织影像的处理过程,是最重要的临床诊断方法之一。早期的CT检查方法是构建专家系统,依赖医学专家人员指导阅片,根据专家经验给出诊断结果。近年,人工神经网络、大模型等人工智能技术驱动的图片处理方法能够从大数据中学习到疾病知识,带来客观、精准、快速的诊断效果。

[0003] 精准的肺部CT分类或分割方法极大辅助医生判断疾病类型、确定病症位置。然而,一方面,诸如肺炎患者的肺部会出现肺泡壁炎症或肺泡内渗出物造成的肺实变、间质性病变或磨玻璃阴影等异常,呈现感染区域多、边缘模糊、感染区域形状异质等复杂特征,致使现有神经网络方法如U-Net、VGGNet等面临存在数据需求大、计算能耗高等不足,难以用于肺部CT检查;另一方面,CT检查涉及了分类、分割等多任务医学图像处理过程,Multi-task CNN、SNN等现有多任务神经网络存在训练难度大、多任务精度低等缺点,限制了人工智能医学影像技术的应用。

[0004] 因此,发展新型人工神经网络方法,提升多任务CT图像处理效率和精度,是突破现有医学影像技术瓶颈的重要途径之一。

发明内容

[0005] 针对现有技术中的CT图像处理过程中的多任务神经网络精度低和计算能耗高不足,本发明提供一种多任务混杂神经网络驱动的CT图像处理方法和类脑诊断系统,可以提高多任务诊断效率,在保证多任务精度的同时降低诊断系统的计算功耗。

[0006] 为实现上述目的,本发明提供以下技术方案:

[0007] 第一方面,本发明提供了一种CT图像处理方法,其包括如下步骤:

[0008] 获取CT图像;

[0009] 生成混杂脉冲-卷积计算层,所述混杂脉冲-卷积计算层由卷积操作和脉冲神经元级联而成,根据所述混杂脉冲-卷积计算层,生成混杂神经网络;

[0010] 生成基于混杂神经网络建立的共同编码器,调用所述编码器对所述CT图像进行编码,生成联合特征;

[0011] 生成基于混杂神经网络建立的多任务解码器,调用所述解码器对所述联合特征进行分类操作和多任务分割操作;

[0012] 生成由所述共同编码器和所述多任务解码器串联的多任务混杂神经网络,利用所述多任务混杂神经网络,输出类脑结果图像。

[0013] 第二方面,本发明提供了一种CT类脑诊断系统,其包括处理器、存储器和显示器,

所述存储器中存储有至少一条指令,所述指令由所述处理器加载并执行以实现如下步骤:

[0014] 获取CT图像;

[0015] 生成混杂脉冲-卷积计算层,所述混杂脉冲-卷积计算层由卷积操作和脉冲神经元级联而成,根据所述混杂脉冲-卷积计算层,生成混杂神经网络;

[0016] 生成基于混杂神经网络建立的共同编码器,调用所述编码器对所述CT图像进行编码,生成联合特征;

[0017] 生成基于混杂神经网络建立的多任务解码器,调用所述解码器对所述联合特征进行分类操作和多任务分割操作;

[0018] 生成由所述共同编码器和所述多任务解码器串联的多任务混杂神经网络,利用所述多任务混杂神经网络,输出类脑结果图像。

[0019] 第三方面,本发明还提供了一种计算机可读存储介质,所述存储介质存储有程序,所述程序被处理器执行实现如前面所述的方法。

[0020] 第四方面,本发明还提供了一种计算机程序产品或计算机程序,该计算机程序产品或计算机程序包括计算机指令,该计算机指令存储在计算机可读存储介质中。计算机设备的处理器可以从计算机可读存储介质读取该计算机指令,处理器执行该计算机指令,使得该计算机设备执行前面所述的方法。

[0021] 本发明与现有技术相比,其有益效果在于:

[0022] (1) 多任务诊断精度高:本发明提出的神经网络从多任务先验知识和图像关联特征出发,整合了编码-解码网络结构和混杂卷积-脉冲计算单元,改进现有单一的损失函数类型,构造子任务特异的耦合型multi-loss函数,进一步借助改进的反向传播算法,训练所提神经网络,提取CT图像分类与分割的多任务联合特征,达到提升肺部CT多任务诊断精度的目的。

[0023] (2) 底层计算功耗低:本发明提出的神经网络增加了LIF脉冲神经元,替代现有卷积神经网络的连续型激活函数和乘法-累加运算,通过脉冲序列(取值0或1)执行离散的信息处理与加法计算,降低所建神经网络的计算能耗,减少CT诊断系统的运行成本。

附图说明

[0024] 为了更清楚地说明本发明实施例中的技术方案,下面将对实施例中所需要使用的附图进行简单的介绍,显而易见地,下面描述中的附图仅仅是本申请的一些实施例,对于本领域普通技术人员来讲,在不付出创造性劳动的前提下,还可以根据这些附图获得其他的附图。

[0025] 附图1是本发明方案的整体技术路线框架图;

[0026] 附图2是多任务混杂神经网络的示意图;附图2(a)是所建基于混杂神经网络的编码器;附图2(b)是所建基于混杂神经网络的多任务编码器;

[0027] 附图3是CT类脑诊断系统和设备的示意图;

[0028] 附图4是新型冠状病毒感染肺部CT的实施例;

[0029] 附图5是所建神经网络在训练集上三个子任务的loss函数以及multi-loss函数的收敛曲线图;附图5(a)是实施例1所建混杂神经网络在训练集上分类任务的损失函数的收敛曲线;附图5(b)是实施例1所建混杂神经网络在训练集上肺部感染区域分割任务的损失

函数的收敛曲线;附图5(c)是实施例1所建混杂神经网络在训练集上肺实质分割任务的损失函数的收敛曲线;附图5(d)是实施例1所建混杂神经网络在训练集上总的损失函数的收敛曲线;

[0030] 附图6是所建神经网络及对比方法分割肺部感染区域的结果图;

[0031] 附图7是所建神经网络中par-SEG模型独立分割肺实质的结果图;

[0032] 附图8是所建神经网络中inf-SEG模型独立分割肺部感染区域的结果图;

[0033] 附图9是所建神经网络及对比方法在测试集上分类指标;

[0034] 附图10是所建神经网络及对比方法在测试集上样本水平的ROC曲线和AUC面积大小;

[0035] 附图11是所建神经网络及对比方法在测试集上分割指标;

[0036] 附图12是所建神经网络及对比方法的计算能耗比图。

具体实施方式

[0037] 下面将结合本发明实施例中的附图,对本发明实施例中的技术方案进行清楚、完整的描述,显然,所描述的实施例仅是本申请一部分实施例,而不是全部的实施例。基于本申请中的实施例,本领域普通技术人员在没有做出创造性劳动前提下所获得的所有其他实施例,都属于本申请保护的范围。

[0038] 实施例:

[0039] 需要说明的是,本发明的说明书和权利要求书及上述附图中的术语“第一”、“第二”等是用于区别类似的对象,而不必用于描述特定的顺序或先后次序。应该理解这样使用的数据在适当情况下可以互换,以便这里描述的本发明的实施例能够以除了在这里图示或描述的那些以外的顺序实施。此外,本发明实施例的术语“包括”和“具有”以及他们的任何变形,意图在于覆盖不排他的包含,例如,包含了一系列步骤或单元的过程、方法、系统、产品或设备不必限于清楚地列出的那些步骤或单元,而是可包括没有清楚地列出的或对于这些过程、方法、产品或设备固有的其它步骤或单元。

[0040] 针对CT图像联合分类与分割的多任务,本发明实施例采用“一个编码器与多个解码器串并联”和“混杂卷积-脉冲计算”的技术构思,构造一种类脑多任务混杂神经网络,克服U-Net、Multi-task CNN、SNN等现有神经网络技术在CT图像处理过程中数据需求大、计算功耗高等局限;结合计算机设备,搭建具备CT图像联合分类与分割功能的类脑诊断系统,提高CT图像的诊断效率,并降低诊断系统的计算功耗。

[0041] 实施例1

[0042] 参见图1至图2,本实施例所提供的一种CT图像处理方法,其可以包括如下步骤:

[0043] 步骤101:获取CT图像。

[0044] 该步骤中,CT图像可以通过电子计算机扫描(Computerized Tomography,CT)得到。

[0045] 步骤102:生成混杂脉冲-卷积计算层,所述混杂脉冲-卷积计算层由卷积操作和脉冲神经元级联而成,根据所述混杂脉冲-卷积计算层,生成混杂神经网络。

[0046] 步骤103:生成基于混杂神经网络建立的共同编码器,调用所述编码器对所述CT图像进行编码,生成联合特征。

[0047] 上述步骤中,所述编码器包括 N_1 个层级结构,每个层级结构包括两个混杂脉冲-卷积计算层和一个池化层,其中,所述混杂脉冲-卷积计算层用于对所述CT图像进行特征提取,混杂脉冲-卷积计算层由卷积操作和脉冲神经元级联而成,所述池化层用于对特征提取后的CT图像进行采样。

[0048] 具体地,构造编码器E,输入是CT图像,如肺部CT,输出是多任务联合特征F。编码器由混杂脉冲-卷积计算层和池化层搭建而成,输入CT图像经混杂卷积-脉冲层进行特征提取,再经过池化层下采样,将特征图尺寸减半,最终得到联合特征F。编码器作为特征提取网络,包含 N_1 个层级结构,每个层级结构由2个混杂脉冲-卷积计算层、1个池化层构成,其中,混杂脉冲-卷积计算层由卷积操作和脉冲神经元级联而成。各个计算单元的公式如下:

[0049] 卷积单元:采用卷积操作,即输入CT一个小区域的像素加权平均后,成为输出图像中对应像素,其中权值由一个卷积核定义,满足

$$[0050] \quad \text{conv}(x^1) = x^1 * K(\omega^1, b) \quad (1)$$

[0051] 其中, x^1 表示第1层输入, $K(w^1, b)$ 表示卷积核函数, w^1 表示第1层权重参数, b 表示偏置参数,权重 w^1 将由下面步骤3)的训练过程确定。第一层输入 x^1 为原始的CT图像,其他层输入 x^l 由神经元产生的脉冲序列定义。

[0052] 脉冲神经元:采用标准leaky integrate-and-fire(LIF)模型进行描述。记 $u(t)$ 为神经元膜电位, $I(t)$ 为神经元输入,主要来自前向神经元, R 为膜电阻, τ 为时间常数,LIF模型如下:

$$[0053] \quad \tau \frac{du(t)}{dt} = -u(t) + RI(t) \\ \text{emit an impulse if } u(t) = u_{\text{thr}} \quad (2)$$

[0054] 根据公式(2),LIF神经元产生脉冲的机制是:当膜电位 u 达到阈值 u_{thr} ,神经元发出一个脉冲(impulse),同时膜电位 u 被重置为初始值 $u_0=0$ 。由此,脉冲神经元的输出为一个脉冲序列,定义为

$$[0055] \quad S(t) = \sum_{t_k \leq t} \sum_k \delta(t - t_k) \quad (3)$$

[0056] 这里, t_k 表示脉冲时刻, δ 为狄拉克脉冲函数: $\delta(t - t_k) = \begin{cases} 1, & t = t_k \\ 0, & \text{otherwise} \end{cases}$

[0057] 混杂卷积-脉冲层:将前向卷积结果作为LIF模型的输入,神经元产生的脉冲序列作为输出,计算如(3),即

$$[0058] \quad h^l = \text{impul}(\text{conv}(x^l)) = \sum_{t_k \leq t} \sum_k \delta(t - t_k) \quad (4)$$

[0059] 第1层采用2个级联的混杂脉冲-卷积计算单元,重复公式(1)和(4)得到:

$$[0060] \quad dh^1 = \text{impul}(\text{conv}(h^1)) \quad (5)$$

[0061] 池化层:采用最大池化操作,进行下采样,即将前向输入图像划分为若干矩形区域,对每个子区域输出元素的最大值,

$$[0062] \quad z^1 = \text{pooling}(dh^1) \quad (6)$$

[0063] 这里, z^1 表示第1层输出, $l=1, \dots, N-1$ 。

[0064] 第 N_1 层仅由2个混杂卷积-脉冲计算层构成,故该层输出直接由神经元的膜电位定义,根据公式(2)计算得出 $u(t)$,根据时间步长 T 取平均,即

[0065] $z^L = u(T) / T$ (7)

[0066] 综上,通过N层混杂神经网络的前向计算,编码器E最终输出为多任务联合特征F。

[0067] 步骤104:生成基于混杂神经网络建立的多任务解码器,调用所述解码器对所述联合特征进行分类操作和多任务分割操作。

[0068] 步骤105:生成由所述共同编码器和所述多任务解码器串联的多任务混杂神经网络,利用所述多任务混杂神经网络,输出类脑结果图像。

[0069] 上述步骤中,所述解码器包括执行所述分类操作的分类模块和执行所述分割操作的分割模块,其中,所述分类模块包括CLS模块,所述分割模块包括实现不同分割功能的par-SEG模块和inf-SEG模块。进一步地,所述CLS模块的分类过程是将编码器输出的联合特征F转换为一维向量,输入分类网络,CLS模块的输出是输出层神经元的脉冲发放频率,分类结果取决于输出层脉冲发放频率最大的神经元的下标,下标代表CT的类别;所述par-SEG模块的分割过程是:输入编码器传来的联合特征,经混杂卷积-脉冲层进行特征再提取,通过转置卷积层执行上采样,将特征图的大小逐层恢复,最终由 1×1 卷积层输出期望区域的分割结果;所述inf-SEG模块相对于所述par-SEG模块还配置有强异质性。

[0070] 具体地,构造多任务解码器D,包括M个并联模块:分类模块(简称CLS模块)、肺实质分割子任务模块(简称par-SEG模块)、肺部感染区域分割子任务模块(简称inf-SEG模块),等等;子模块的个数M可以根据诊断任务的需求调整;输入是步骤1)的多任务联合特征F,各个模块输出为各子任务结果。

[0071] CLS模块是由 N_2 层全连接单元构成的分类网络,每个层级结构由脉冲神经元构成,神经元采用公式(2)(3)所给的LIF模型,神经元个数由联合特征图F的维数决定。CT图像的分类过程是:将编码器输出的联合特征图F转换为一维向量,输入分类网络,CLS模块的输出是输出层神经元的脉冲发放频率,分类结果取决于输出层脉冲发放频率最大的神经元的下标,下标代表CT的类别。

[0072] par-SEG模块采取与编码器E对称的网络结构,由混杂脉冲-卷积计算层和转置卷积层搭建而成,包含 N_1 个层级结构,每个层级结构由2个混杂脉冲-卷积层、1个转置卷积层构成。CT图像肺实质的分割过程是:输入编码器E传来的联合特征图F,经混杂卷积-脉冲层进行特征再提取,通过转置卷积层执行上采样,将特征图的大小逐层恢复,最终由 1×1 卷积层输出期望区域的分割结果。

[0073] 混杂脉冲-卷积层的计算公式如步骤1)公式(5)所示。转置卷积层的计算公式如下:

[0074] $outsize_l = stride \times (insize_l - 1) + kernel$ (8)

[0075] 这里, $outsize_l$ 和 $insize_l$ 分别表示该层的输出和输入, $l=1, \dots, N_1-1$,kernel为奇数,取值3或5。

[0076] inf-SEG模块具有与par-SEG模块相似的网络结构和计算单元,CT图像感染区域的分割过程也与肺实质分割过程一致。不同之处在于肺实质为分布于两侧的整块结构,而肺部感染区域较多,分布于不同位置,且感染区域形状大小不一,具有强异质性,因此对应较复杂的loss函数,才能保证有效提取感染区域分割的异质特征。

[0077] 一些实施例中,还包括对所述编码器和所述解码器的训练步骤:

[0078] 步骤201:生成对应于所述多任务混杂神经网络中分类模块和多任务分割模块的

损失函数以及总体损失函数,将训练样本输入至所述编码器和所述解码器;

[0079] 步骤202:调用所述损失函数并调整所述分类器和所述多任务分割模块的损失函数的相关参数,用于使所述编码器和所述解码器的损失下降;

[0080] 步骤203:根据所述训练样本的结果图像调整的所述损失函数的相关参数并计算所述分类模型和所述多任务分割模块的损失;

[0081] 步骤204:根据所述损失进行基于脉冲的反向传播训练优化所述多任务混杂神经网络,训练优化直至达到预设的训练停止条件,得到最优的所述多任务混杂神经网络。

[0082] 具体地,多任务混杂神经网络训练。根据分类、分割等子任务的异质性,设计有效的训练损失(Loss)函数及反向传播算法,保证所建神经网络学习到关键权重参数。

[0083] 本方案采用Multi-loss函数训练多任务混杂神经网络,训练函数定义如下:

[0084] 针对分类任务,损失函数采用MSE(Mean squared error)Loss形式,即

$$[0085] \quad L_i(p, y) = \frac{1}{2} \sum_r (p_r - y_r)^2 \quad (9)$$

[0086] 这里,pr为CLS模块的输出类别,yr为真实类别标签,下标i表示第i个任务,r表示训练样本数。

[0087] 针对两个分割任务,即肺实质、肺部感染区域分割,考虑待分割区域仅为整个肺部的较少部分,即CT图像的大部分像素都是正样本,小部分为待分割的负样本,呈现样本分布失衡情形。故,本方案的损失函数采用Focal Loss形式:

$$[0088] \quad L_i(p, y) = - \sum_r (1 - \hat{p}_r)^\alpha \log(\hat{p}_r) \quad (10)$$

$$[0089] \quad \hat{p}_r = \begin{cases} p_r, & y_r = 1 \\ 1 - p_r, & y_r = 0 \end{cases}$$

[0090] 目的是增加训练网络对分割任务负样本数量较少的前景区域的关注,进而增强分割特征的提取,其中,phat表示输出类别与真实标签的接近程度, $\alpha \in (0, 1)$ 表示调节因子,log表示自然对数。

[0091] 为提高多任务训练效果,本方案采用正则化加权multi-loss函数,由M个子任务模块的Loss构成,定义如下:

$$[0092] \quad mL(p, y) = \sum_{i=1}^M \lambda_i L_i(p, y) \quad (11)$$

[0093] 这里,lamdai>0表示子任务i的加权因子,M表示子任务的个数。

[0094] 进一步,本方案采用脉冲反向传播算法,目的是通过最小化上述Multi-loss函数(11),学习到最优权重参数w,即:

$$[0095] \quad \begin{aligned} & \text{Minimize } mL(p, y) \\ & \text{Subject to } W, b \end{aligned} \quad (12)$$

[0096] 根据公式(4)、(5),mL(p, y)是权重参数w和偏置参数b的函数,要优化mL(p, y),必须得到函数mL(p, y)分别关于对w和b的梯度。本方案采用定常的偏置参数b,故只需计算mL对w的梯度。所建多任务混杂神经网络具有层级结构,根据梯度反向传播规则,梯度可以从最后输出层沿着多个隐藏层,一直反向传播至输入层。因此,得到如下链式求导法则:

$$[0097] \quad \frac{\partial mL}{\partial W^l} = \frac{\partial mL}{\partial p^l} \frac{\partial p^l}{\partial net^l} \frac{\partial net^l}{\partial W^l} \quad (13)$$

[0098] 这里, $\partial mL / \partial p^l$ 表示 multi-loss 函数关于 p^l 的偏导数, net^l 表示脉冲神经元的输出, 表示 multi-loss 函数关于 p^l 的偏导数, 其他偏导数项依此类推。

[0099] 在前馈传播中, 卷积和脉冲被集成为一个混杂神经元模型, 其中, 根据原始图像和前次卷积确定脉冲神经元的计算公式。每层神经元的数量 n 由前向卷积大小确定; 脉冲神经元的输入在不同层间是不同的。对于第 1 层, 脉冲神经元的输入向量定义为:

$$[0100] \quad net^1(t) = \text{conv}(x^0) = K * x^0$$

[0101] 对于第 1 层, $l=2, \dots, N$, 脉冲神经元的输入定义为:

$$[0102] \quad net_i^l(t) = \sum_{r=1}^{n_{l-1}} w_j^{l-1} x_j^{l-1}(t) = W^{l-1} x^{l-1}(t)$$

[0103] 这里, W^{l-1} 表示上一层权重, $x^{l-1}(t)$ 表示上一层神经元传来的脉冲序列, 定义同公式 (3)。

[0104] 由于脉冲序列的不连续性, 如上述公式 (4) 和 (5), 不能直接采用经典的梯度下降法对所建多任务混杂神经网络进行训练, 故采用基于脉冲的反向传播算法。下面逐层给出梯度 $\partial mL / \partial w$ 的计算方案。

[0105] 对最终输出层, $l=N$, 代入 (7), 梯度计算满足:

$$[0106] \quad \begin{aligned} \frac{\partial mL}{\partial W^L} &= \frac{\partial mL}{\partial p^L} \frac{\partial p^L}{\partial z^L} \frac{\partial z^L}{\partial net^L} \frac{\partial net^L}{\partial W^L} \\ &= \frac{\partial mL}{\partial p^L} \frac{\partial p^L}{\partial z^L} \frac{1}{T} x^L \end{aligned} \quad (14)$$

[0107] 对隐含层 $l, l=1, 2, \dots, N-1$, 公式 (10) 表明输出 z 是不连续的, 因此不可微, 故采用伪导数方法来估计 (12) 式中各项导数。具体地, 根据 LIF 模型 (2), 神经元的激活函数由下式给出:

$$[0108] \quad \hat{a}_{IF}(t) = \frac{1}{u_{thr}} net(t)$$

[0109] 进一步增加 Leaky 项可得:

$$[0110] \quad a_{IF}(t) = \left[1 + S(t) \frac{df(t)}{dt} \right] \frac{1}{u_{thr}} net(t)$$

[0111] 其中, $f(t) = \sum_k e^{-\frac{t-t_k}{\tau}}$, $S(t)$ 表示脉冲序列, 如公式 (3), 表示在总前向传播时间内神经元的输出脉冲数。使用激活函数 $a_{IF}(t)$ 代替原始的不连续输出 z^l , 可得如下导数:

$$[0112] \quad \frac{\partial z^l}{\partial net^l} = \frac{a_{IF}(t)}{\partial net^l} = \left[1 - \frac{1}{\tau} S(t) \sum_k e^{-\frac{t-t_k}{\tau}} \right] \frac{1}{u_{thr}}$$

[0113] 回顾链式法则 (12), 有

$$[0114] \quad \frac{\partial mL}{\partial W^l} = \frac{\partial mL}{\partial z^l} \left[1 - \frac{1}{\tau} S(t) \sum_k e^{-\frac{t-t_k}{\tau}} \right] \frac{1}{u_{thr}} x^l \quad (15)$$

[0115] 综上公式 (14) 和 (15), 类似于在 VGG 等卷积神经网络中反向传播梯度, 在多任务混杂神经网络中反向传播梯度, 可以达到训练所有层中所有权值参数 w 的目的。权重的更新规则如下:

$$[0116] \quad W^l \leftarrow W^l - \eta \frac{\partial m L}{\partial W^l}$$

[0117] 式中, $0 < \eta < 1$ 表示学习率, $l = 1, 2, \dots, N$ 。

[0118] 综上, 本发明的图像处理方法有以下优点:

[0119] (1) 多任务诊断精度高: 本发明提出的神经网络从多任务先验知识和图像关联特征出发, 整合了编码-解码网络结构和混杂卷积-脉冲计算单元, 改进现有单一的损失函数类型, 构造子任务特异的耦合型 multi-loss 函数, 进一步借助改进的反向传播算法, 训练所提神经网络, 提取 CT 图像分类与分割的多任务联合特征, 达到提升肺部 CT 多任务诊断精度的目的。

[0120] (2) 底层计算功耗低: 本发明提出的神经网络增加了 LIF 脉冲神经元, 替代现有卷积神经网络的连续型激活函数和乘法-累加运算, 通过脉冲序列 (取值 0 或 1) 执行离散的信息处理与加法计算, 降低所建神经网络的计算能耗, 减少 CT 诊断系统的运行成本。

[0121] 为证明本发明计算能耗的优点, 本发明还提供了一种人工神经网络的计算能耗度量方法。对于一般的卷积层, 计算能耗的度量公式为:

$$[0122] \quad E_{\text{conv}} = \#FP_{\text{conv}} \times E_{\text{mac}}$$

[0123] 对于一般的脉冲神经元层, 计算能耗的度量公式为:

$$[0124] \quad E_{\text{impu}} = \#FP_{\text{impu}} \times E_{\text{add}}$$

$$[0125] \quad = R_{\text{fire}} \times \#FP_{\text{conv}} \times E_{\text{add}}$$

[0126] 对于本发明所提的混杂卷积-脉冲神经元层, 计算能耗的度量公式为:

$$[0127] \quad E_{\text{hybrid}} = \#FP_{\text{layer1}} \times E_{\text{mac}} + (\#FP - \#FP_{\text{layer1}}) \times R_{\text{fire}} \times E_{\text{add}} \quad (16)$$

[0128] 式中, $\#FP$ 表示网络中每秒 FP (浮点) 操作的数量, 一个 32 位 MAC (乘法累加) 运算操作的能量消耗为 $E_{\text{mac}} = 4.6 \text{ pJ}$, 一个 32 位 ADD (累加) 运算操作的能耗为 $E_{\text{add}} = 0.1 \text{ pJ}$, 前者能耗是后者的 5.1 倍; R_{fire} 表示神经元的脉冲发放频率, 满足:

$$[0129] \quad R_{\text{fire}} = \sum_{k=1}^T C[k] / \#Neurons$$

[0130] $C[k]$ 表示 k 个时间步的总脉冲计数, $\#Neurons$ 表示该层神经元的数量, R_{fire} 取值 0 到 1, $R_{\text{fire}} = 1$ 代表该层每个神经元在 T 时间步长内仅触发一次, 这种情况意味着脉冲神经元层 FP 操作数量与对应卷积层级的相同。综合上述四个公式, 有:

$$[0131] \quad E_{\text{hybrid}} \leq E_{\text{conv}} \quad (17)$$

[0132] 证明了相比对应的卷积网络, 所建混杂网络具有较低的计算能耗优点。

[0133] 实施例 2

[0134] 参见图 3, 基于同一发明构思, 本发明实施例还提供一种 CT 类脑诊断系统, 其包括处理器和存储器, 所述存储器中存储有至少一条指令, 所述指令由所述处理器加载并执行以实现如下步骤:

[0135] 获取 CT 图像;

[0136] 生成混杂脉冲-卷积计算层, 所述混杂脉冲-卷积计算层由卷积操作和脉冲神经元级联而成, 根据所述混杂脉冲-卷积计算层, 生成混杂神经网络;

[0137] 生成基于混杂神经网络建立的共同编码器, 调用所述编码器对所述 CT 图像进行编码, 生成联合特征;

[0138] 生成基于混杂神经网络建立的多任务解码器,调用所述解码器对所述联合特征进行分类操作和多任务分割操作;

[0139] 生成由所述共同编码器和所述多任务解码器串联的多任务混杂神经网络,利用所述多任务混杂神经网络,输出类脑结果图像。

[0140] 具体地,诊断系统由所述多任务神经网络技术驱动,可以在不需要医师专家阅片的情况下,自主实现肺部CT的阴性-阳性分类、肺部多样异构病症的精准分割,同时极大降低诊断过程的计算能耗,称为CT类脑诊断系统。具体可以按如下步骤搭建:

[0141] 步骤301:采用具有存储器、处理器、显示器、网络连接等组件的电子设备,设置APP,记为“CT类脑”,通过python语言,写入上述所建多任务混杂神经网络。

[0142] 步骤302:通过存储器获取新的CT图像,输入“CT类脑诊断”APP,运行APP,显示器按电子命令,展示多任务混杂神经网络的输出,含:CT类别、肺实质分割图、肺部感染区域,同时展示一个预测指令,给出患者的感染程度。

[0143] 注意,所述电子设备可以是台式计算机、便携式计算机或手机等设备,可以提供脉冲网络计算模块和可视化界面。

[0144] 由于该系统是本发明实施例的CT图像处理方法对应的系统,并且该系统解决问题的原理与该方法相似,因此该系统的实施可以参见上述方法实施例的实施过程,重复之处不再赘述。

[0145] 实施例3

[0146] 下面结合新型冠状病毒感染患者的肺部CT图像,给出一个优选的实施例,如附图4,对本发明方案进行详细说明和具体验证,通过所给实施例,解决本发明提到的两个关键技术问题。应当理解,所给实施例仅用以解释本发明,不用于限定本发明。

[0147] 本优选实施例的具体实施过程包括:第一、获取电子计算设备;第二、收集CT图像;第三、搭建多任务混杂神经网络;第四、展示CT多任务诊断结果。

[0148] 步骤401、准备电子计算机。本实施例的硬件包括便携式笔记本1台:配置GeForce RTX 3080Ti显卡,17英寸显示器,电源1套,键鼠1套。

[0149] 步骤402、制备CT数据集iData。本实施例使用的CT数据集来自新型冠状病毒感染患者及对照组,包括9,701张大小为 256×256 的肺部CT图像,记为I,分别来自数据集COVID-19CT_scans (<https://www.kaggle.com/datasets/andrewmvd/covid19-ct-scans>) 和数据集iCFCT(文献[1])。COVID-19CT_scans收集了20名确诊新型冠状病毒感染患者的CT图像,获取1,194张标记为positive的肺部CT图像,且每张CT图像由放射科专家给出肺实质、感染区域的分割标签;iCFCT收集了1,521位患者的肺部CT,获取8,507张标记为negative的CT图像。

[0150] 步骤403、本实施例对照所述的技术方案,搭建由编码器E和多任务解码器D级联构成的多任务混杂神经网络。具体参数如下:

[0151] S1) 构建具有5个层级结构的编码器E。在网络结构方面,每个层级由2个混杂脉冲-卷积计算层和1个池化层构成,第5层级包含2个混杂脉冲-卷积计算层。在卷积大小和脉冲神经元的选取方面,首先,考虑输入图像I是 256×256 的灰度图,第1层卷积大小选取为;其次,第1层脉冲神经元的个数根据前向卷积大小得到,脉冲神经元的模型采用LIF模型(2);对于其他层级,卷积大小、脉冲神经元的规格依次类推计算得到。

[0152] S2) 构造多任务解码器D,由3个并联子模块构成:CLS模块、par-SEG模块、inf-SEG模块。

[0153] CLS模块的用途是判断CT图像的类别,即阳性或阴性。具体参数为:采用由2层全连接单元构成的分类器,每个层级由脉冲神经元构成,CLS模块第1层包括F维度大小个神经元,第2层包括2个神经元,分别对应了2个类别:positive或negative。分类结果取决于第2层脉冲发放频率最大的神经元的下标。

[0154] par-SEG模块的用途是分割肺实质,即通过像素差异将肺实质从胸腔背景中分离出来。具体参数为:在网络结构方面,采用包含5个层级结构,每个层级结构由2个混杂卷积-脉冲单元和1个转置卷积层构成。在卷积大小和神经元规则方面,par-SEG模块第1层采用卷积大小为256X256,据此第1层神经元的个数取值为256X256,转置卷积规模选取256X256,其它层的参数依次类推,par-SEG模块第5层仅含2个混杂卷积-脉冲单元,其输出为256X256像素矩阵,代表肺实质分割结果。

[0155] inf-SEG模块的用途是分割肺部感染区域,其网络结构、卷积和脉冲神经元的参数配置类似于par-SEG模块的规格。不同之处在于inf-SEG模块第5层输出的256X256像素矩阵,代表肺部不同位置、不同大小的感染区域分割结果。

[0156] S3) 采用数据集iData,训练上述多任务混杂脉冲神经网络,具体流程包括:首先,对于训练过程中每轮epoch,从阴性CT图像中随机抽样20%,选取1,701张阴性样本,同时选取1,194张阳性样本,构成一个包含2,895张CT图像的数据集,再按照8:1:1的比例,划分为训练集、验证集和测试集。

[0157] 其次,按照技术方案步骤S3),使用训练集,每轮epoch,构造三个子任务的Loss函数:L1、L2、L3,故本实施例采用的Multi-loss函数定义如下:

$$[0158] \quad mL(p, y) = \lambda_1 L_1 + \lambda_2 L_2 + \lambda_3 L_3$$

[0159] 另外,根据脉冲反向传播算法,计算上述Multi-loss函数关于权重w的梯度,得到,通过多任务混杂神经网络中反向传播梯度,优化权重参数w,达到优化上述Multi-loss函数的目的。

[0160] 每轮epoch,所有训练样本在所建神经网络中都会进行一次前馈传播和一次反向传播。

[0161] 附图5给出了三个子任务Loss函数、Multi-loss函数的收敛过程,这些曲线说明经过5轮训练后,这些loss函数都趋近0,即权重参数w趋近最优值,意味着所建神经网络学习到了CT诊断的多任务特征。

[0162] 步骤404、通过显示器,展示CT多任务诊断结果,并计算图像任务指标,说明所建多任务混杂神经网络相比现有技术的优势。具体流程是:随机选取验证集、测试集中的样本,输入到上述多任务混杂神经网络,经过前馈计算,得到各个模块的输出。输入测试集CT样本,三个子任务的输出由附图6、7、8给出。

[0163] 为说明本发明技术相对现有技术的优势,本实施例进一步计算了有关图像分类、图像分割的各项指标,包括分类准确度(Accuracy)、特异度(Specificity)、灵敏度(Sensitivity),ROC曲线、AUC面积,Dice系数、IoU量测以及神经网络计算能耗,用于评价所建多任务混杂神经网络的效果。

[0164] 对于CT分类任务,所建神经网络在测试集上取得了89.9%准确度、90.2%特异度

以及88.9%灵敏度,相对现有UNet至少提升了12.1%。附图9给出了具体的对比技术与结果。为进一步评估分类性能,附图10给出了所建网络在测试集上样本水平的ROC(receiver operating characteristic)曲线,及对比技术的ROC曲线,可以观察到,所建网络的ROC曲线下面积(即AUC)为0.99,大于对比方法,这些数字指标说明了所建网络具有更好的稳健性。

[0165] 对于肺实质分割任务,所建神经网络在测试集上取得的Dice系数为0.915,IoU量测为0.844,相比现有U-Net技术提升了至少23%。在肺部感染区域分割任务中,所建网络取得了0.532的Dice系数和0.366的IoU,相比现有U-Net技术提升了15%。附图11给出了具体的对比技术与结果,这些数字指标说明所建所任务混杂神经网络的分割效果优化单任务U-Net、单任务脉冲神经网络等现有技术;结合附图7给出的分类指标,所建多任务混杂神经网络在学习分类、分割等多任务图像特征时,能够融合分类与分割任务的关联性,提升分类或分割等单任务效果。

[0166] 最后,为说明所建神经网络的计算能耗优势,按照技术方案优点第二优点给出的公式(16)、(17),计算能耗比: $E_{\text{hybrid}}/E_{\text{conv}}$,本实施例对比了所建网络与对照网络的计算能耗,运用归一化,即设置 $E_{\text{conv}}=1$,附图12说明了所建神经网络的计算能耗至少降低了80%。

[0167] 综上,通过附图4给出的实施例以及附图9、10、11、12给出的对比指标,说明了所建神经网络具有学习多任务CT图像特征的能力,特别是关于CT图像类别、不同区域分割等关键特征的学习,取得了比现有技术更好的效果,而且所建神经网络的计算能耗远低于对照的卷积神经网络,因此,所建多任务混杂神经网络驱动的肺部CT诊断系统,具有多任务精度高、底层计算能耗低的优势,有望更好、更省地辅助医师专家治疗冠肺炎患者。

[0168] 其他实施例可以采用不同类型的医学图像数据,如乳腺超声成像、脑部核磁共振成像,将所建类脑多任务混杂神经网络方法扩展应用于乳腺癌、抑郁症和脑肿瘤等疾病的辅助诊断。

[0169] 实施例4

[0170] 基于同一发明构思,本发明实施例还提供一种计算机可读存储介质,所述存储介质中存储有至少一条指令、至少一段程序、代码集或指令集,所述至少一条指令、所述至少一段程序、所述代码集或指令集由处理器加载并执行以实现如上所述的CT图像处理方法。

[0171] 本领域普通技术人员可以理解上述实施例的各种方法中的全部或部分步骤是可以通过程序来指令相关的硬件来完成,该程序可以存储于一计算机可读存储介质中,存储介质包括只读存储器(Read-Only Memory,ROM)、随机存储器(Random Access Memory,RAM)、可编程只读存储器(Programmable Read-only Memory,PROM)、可擦除可编程只读存储器(Erasable Programmable Read Only Memory,EPRM)、一次可编程只读存储器(One-time Programmable Read-Only Memory,OTPRM)、电子抹除式可复写只读存储器(Electrically-Erasable Programmable Read-Only Memory,EEPROM)、只读光盘(Compact Disc Read-Only Memory,CD-ROM)或其他光盘存储器、磁盘存储器、磁带存储器、或者能够用于携带或存储数据的计算机可读的任何其他介质。

[0172] 由于该存储介质是本发明实施例的CT图像处理方法对应的存储介质,并且该存储介质解决问题的原理与该方法相似,因此该存储介质的实施可以参见上述方法实施例的实施过程,重复之处不再赘述。

[0173] 实施例5

[0174] 在一些可能的实施方式中,本发明实施例的方法的各个方面还可以实现为一种程序产品的形式,其包括程序代码,当程序产品在计算机设备上运行时,程序代码用于使计算机设备执行本说明书上述描述的根据本申请各种示例性实施方式的CT图像处理方法的步骤。其中,用于执行各个实施例的可执行的计算机程序代码或“代码”可以用诸如C、C++、C#、Smalltalk、Java、JavaScript、Visual Basic、结构化查询语言(例如,Transact-SQL)、Perl之类的高级编程语言或者用各种其它编程语言编写。

[0175] 在本说明书的描述中,参考术语“一个实施例”、“一些实施例”、“示例”、“具体示例”、或“一些示例”等的描述意指结合该实施例或示例描述的具体特征、结构、材料或者特点包含于本发明的至少一个实施例或示例中。在本说明书中,对上述术语的示意性表述不必针对的是相同的实施例或示例。而且,描述的具体特征、结构、材料或者特点可以在一个或多个实施例或示例中以合适的方式结合。此外,在不相互矛盾的情况下,本领域的技术人员可以将本说明书中描述的不同实施例或示例以及不同实施例或示例的特征进行结合和组合。

[0176] 上述实施例只是为了说明本发明的技术构思及特点,其目的是在于让本领域内的普通技术人员能够了解本发明的内容并据以实施,并不能以此限制本发明的保护范围。凡是根据本发明内容的实质所做出的等效的变化或修饰,都应涵盖在本发明的保护范围内。






图1



(a)



(b)

图2




图3




图4




图5




图6




图7




图8

Model	Accuracy	Specificity	Sensitivity
INN ¹	0.689	0.687	0.750
HUST-19 ²	0.782	0.812	0.832
Multi-CNN ³	0.876	0.877	0.863
Hybrid ⁴	0.899	0.902	0.889

¹INN: 单任务脉冲神经网络

²HUST-19: 单任务卷积神经网络, 来自文献[1]

³multi-task CNN: 多任务卷积神经网络, 架构与hybrid相同

⁴hybrid: 所建多任务混杂神经网络

图9




图10

Model	Lung segmentation		Infect segmentation	
	Dice	IoU	Dice	IoU
I-UNet ¹	0.628	0.458	0.157	0.136
UNet ²	0.777	0.636	0.231	0.216
Multi-CNN ³	0.790	0.653	0.285	0.238
Hybrid ⁴	0.915	0.844	0.532	0.366

¹I-UNet: 由混杂卷积-脉冲层构建的UNet网络

²UNet: 标准UNet网络, 来自文献[2]

³multi-task CNN: 全卷积多任务神经网络, 架构与hybrid相同

⁴hybrid: 所建多任务混杂神经网络

图11




图12