



(10) 授权公告号 CN 113781461 B

(45) 授权公告日 2024. 07. 19

(21) 申请号 202111089390.0

(22) 申请日 2021.09.16

(65) 同一申请的已公布的文献号

申请公布号 CN 113781461 A

(43) 申请公布日 2021.12.10

(73) 专利权人 人工智能与数字经济广东省实验室(广州)

地址 510220 广东省广州市海珠区新港东路2429首层自编051房

(72) 发明人 曾栋 湛高峰 王子丹

(74) 专利代理机构 广州高航知识产权代理有限公司 11530

专利代理师 刘艳玲

(51) Int. Cl.

G06T 7/00 (2017.01)

G06T 11/00 (2006.01)

G06T 5/60 (2024.01)

G06T 5/73 (2024.01)

G06N 3/0442 (2023.01)

G06N 3/0455 (2023.01)

G06N 3/0464 (2023.01)

G06N 3/0475 (2023.01)

G06N 3/091 (2023.01)

G06N 3/094 (2023.01)

G06N 3/084 (2023.01)

G06N 3/088 (2023.01)

G06N 3/0895 (2023.01)

(56) 对比文件

CN 107481297 A, 2017.12.15

CN 109035169 A, 2018.12.18

审查员 宋亚静

权利要求书4页 说明书10页 附图1页

(54) 发明名称

一种病人智能监控排序方法

(57) 摘要

本发明提供了一种病人智能监控排序方法,包括S1、基于深度识别模型对CT扫描协议进行自适应优化;S2、基于对抗技术对CT伪影进行辨识与自动校正;S3、基于增量学习技术进行CT定量成像;S4、基于迁移学习技术对CT影像进行智能分析;S5、对CT影像进行辅助决策。本发明构建了一种面向急诊病人智能监控排序的策略网络,网络架构可以基于多种深度卷积网络技术,比如高维卷积神经网络,目的是筛选心血管急重病人CT投影数据;高维卷积神经网络最终确定图像是否包含急性心血管疾病,从而使图像按照“急重优先”顺序而非原本采集的顺序进行诊断,优化有限的医院的医疗资源,达到快速诊断和治疗“急重优先”的病人。

S1、基于深度识别模型对CT扫描协议进行自适应优化

S2、基于对抗技术对CT伪影进行辨识与自动校正

S3、基于增量学习技术进行CT定量成像

S4、基于迁移学习技术对CT影像进行智能分析

S5、对CT影像进行辅助决策

1.一种病人智能监控排序方法,其特征在于,包括:

S1、基于深度识别模型对CT扫描协议进行自适应优化;

S2、基于对抗技术对CT伪影进行辨识与自动校正;

S3、基于增量学习技术进行CT定量成像;

S4、基于迁移学习技术对CT影像进行智能分析;

S5、对CT影像进行辅助决策;

所述S3包括:

S31、构建低剂量CT定量成像监督学习网络:

低剂量CT定量成像监督学习网络包含全连接滤波层、正弦反投影层以及残差卷积神经网络,其中全连接滤波层基于滤波反投影算法滤波核进行优化设计,正弦反投影层对应于滤波反投影算法中的反投影算子,残差卷积神经网络用于进一步优化重建结果,网络代价函数设计为2范数均方根误差,记为: $E(\Theta) = \frac{1}{|N|} \sum_{i=1}^N \|\bar{x}_{H_i}(\Theta) - x_{H_i}^{ref}\|_2^2$ 其中 $\bar{x}_H$ 为CT重建网络的最终预测图像, x_H^{ref} 为目标CT图像, N 为训练样本数, Θ 为需要学习的参数;

S32、构建半监督增量学习网络:将外源获取的含噪CT投影数据通过多种形变场后输入预先训练好的FBP net,对CT图像结果进行自适应加权融合,得到融合后的高质量CT目标图像,对进行FBP net参数再次深度优化,获得半监督定量成像模型;

S33、构建CT定量成像无监督增量学习网络;基于Log变换前含噪CT投影数据统计特性以及CT投影数据高阶导数稀疏性设计CT定量成像无监督增量学习网络;基于最大后验概率框架构建深度学习网络中的目标函数,其包含基于似然函数的数据保真项以及基于分段线性的先验信息项,该目标函数能够更加准确地描述CT投影数据,且能沿着梯度方向进行训练优化,其表达式为:

$$L(G, \theta) = \sum_{y_i \in C_1} \left(\sum_{j=1}^N \left(\frac{\|I_i - G_i\|_2^2}{2\sigma^2} - G_i \ln I_{0j} + G_j f_{\theta}(y_i)_j + \ln(G_j!) \right. \right. \\ \left. \left. + I_{0j} e^{f_{\theta}(y_i)_j} \right) + k \left\| \ln(D_2 f_{\theta}(y_i) + \varepsilon) \right\|_1 \right)$$

其中, C_1 表示含噪CT投影训练数据集, y_i 为第 i 个含噪CT投影训练数据, N 表示数据集个数, G 表示满足复合泊松统计特性的X射线光子数, I 代表探测器接收的光子数, I_i 代表第 i 个探测器接收的光子数, G_i 代表 I_i 的近似中间值, $G_j!$ 表示第 j 个投影下 G 的乘值, I_{0j} 表示第 j 个投影下的入射光子数, ε 代表电子噪声,且服从均值为0,方差为 σ^2 的高斯分布, D_2 表示二阶差分算子, f_{θ} 代表无监督学习网络映射,其中 θ 为网络映射中需要学习的参数,利用滤波反投影算法重建得到高质量CT图像, $f_{\theta}(y_i)_j$ 代表对于第 i 个含噪CT投影训练数据 y_i 在像素 j 上无监督学习网络映射;

所述S4包括:

S41、构建基于视频景深迁移学习技术的血管定性辨识网络,包括:

S4101、构建动态景深区域识别网络:训练集被定义为 $s = \{(x_i, y_i), i = 1, 2, 3, \dots, n\}$, 其中 x_i 为第 i 时间帧三维序列输入图像, y_i 为第 i 时间帧标签数据, $\hat{y}_i$ 为网络输出结果,其代价函数为:

$$L = \frac{1}{n} \sum_{i=1}^n y_i \log \hat{y}_i + (1 - y_i) \log (1 - \hat{y}_i)$$

S4102、构建视频景深迁移学习网络；

S42、构建基于医学多模态迁移成像的血管定量识别网络，包括：

S4201、构建血管定量识别网络：训练集被定义为 $S = \{(X_i, Y_i), i = 1, 2, 3, \dots, n\}$ ，其中 X_i 为第 i 幅输入图像， $Y_i \in \{0, 1\}$ 为第 i 幅输入图像的标签，其中 $Y_i = 1$ 定义为异常图像， $Y_i = 0$ 定义为非异常图像；

定义 $\hat{Y}_{ik}$ 为第 i 幅输入图像的第 k 个像素的概率，其中 $k = \{1, 2, 3, \dots, |X_i|\}$ ， $|X_i|$ 表示为 X_i 总的像素个数，若 $\hat{Y}_i$ 为图像水平预测的概率图，则 $\hat{Y}_i$ 通过像素水平的所有 $\hat{Y}_{ik}$ 计算得到，其代价函数为：

$$\begin{cases} L_{\text{MIL}} = - \sum_i (I(Y_i = 1) \log(\hat{Y}_{ik}) + I(Y_i = 0) \log(1 - \hat{Y}_{ik})) \\ \hat{Y}_i = \left(\frac{1}{|X_i|} \sum_{k=1}^{|X_i|} \hat{Y}_{ik}^r \right)^{1/r} \end{cases}$$

其中 $I(\cdot)$ 为指示函数， $\hat{Y}_i$ 由 Soft max Function 计算得到， r 为控制参数； L_{MIL} 表示代价函数；

S4202、构建多模态迁移学习网络。

2. 根据权利要求1所述的一种病人智能监控排序方法，其特征在于，所述S1包括：

S11、构建脏器区域解剖特征辨识网络；

S12、构建CT个性化扫描协议任务导向网络。

3. 根据权利要求2所述的一种病人智能监控排序方法，其特征在于，所述S11包括：

S1101、构建三维定位像成像子网络：

包括噪声估计块，伪影估计块和图像滤波块的深度残差学习子网络，其中噪声估计块、伪影估计块和图像滤波块分别通过残差学习网络、多尺度小波和卷积神经网络进行处理；

基于多尺度小波变换的处理流程进行伪影估计，通过迭代的方法进一步提高微剂量图像的图像质量，最终获得三维定位像；

S1102、构建脏器区域辨识子网络：

基于深度残差学习网络输出的恢复后的微剂量三维定位图像作为辨识网络的输入；

其中脏器区域辨识网络包含编码过程和解码过程；

其中编码过程采用残差块的结构，解码过程采用全卷积网络；训练集被定义为 X ，其中 X_i 为第 i 幅输入图像， Y_i 为第 i 幅输入图像的标签，其中 I 定义为不同的重建目标区域；同时定义 $\hat{Y}_{ik}$ 为第 i 幅输入图像的第 k 个像素的概率； $\hat{Y}_i$ 为图像水平预测的概率图，则通过像素水平的所有计算得到，其代价函数为：

$$\begin{cases} L = - \sum_i (I(Y_i = 1) \log(\hat{Y}_{ik}) + I(Y_i = 0) \log(1 - \hat{Y}_{ik})) \\ \hat{Y}_i = \left(\frac{1}{|X_i|} \sum_{k=1}^{|X_i|} \hat{Y}_{ik}^r \right)^{1/r} \end{cases}$$

三维定位像成像子网络和脏器区域辨识子网络通过级联得到最终的脏器区域解剖特征辨识网络,L表示代价函数,r表示控制参数。

4. 根据权利要求3所述的一种病人智能监控排序方法,其特征在于,所述S12包括:

S1201、构建深度识别网络,所构建的深度识别模型是基于双向深度递归网络;

S1202、利用由脏器区域解剖特征辨识网络中获得的三维定位像和目标脏器区域,作为高维图像特征提取网络的输入,提取出三维定位像和目标脏器区域的形态学特征 $W_{\text{patient}_j}^2$,纹理特征 W_{scout}^2 ;

S1203、个性化扫描参数估计,基于任务驱动,病人驱动的多目标优化,

其中,所述S1203中个性化扫描参数估计的优化过程通过一个目标方程求解

$$\Phi(\Omega_A, \Omega_R) = \frac{\left[\iiint W_{\text{Task}_j}^2 T_j^2(\Omega_A, \Omega_R) df_x df_y df_z \right]^2}{\iiint S_j(\Omega_A, \Omega_R) T_j^2(\Omega_A, \Omega_R) W_{\text{Task}_j}^2 df_x df_y df_z}, \text{ 其中 } \Omega_A \text{ 为待求解的自适应扫描参}$$

数; Ω_R 为待求解的自适应重建参数; S表示局部噪声功率谱的估计, T表示局部调制传递函数的估计, $W_{\text{Task}_j}^2$ 是基于任务驱动结合病人驱动的参数估计, 包含病人核心信息 $W_{\text{patient}_j}^2$ 和三维定位图像高维形态学特征 $W_{\text{patient}_j}^2$, 纹理特征 $W_{\text{scout}_j}^2$, 即 $W_{\text{Task}_j}^2 = F(W_{\text{patient}_j}^2, W_{\text{scout}_j}^2)$; 最后通过ADMM-Net网络优化出每个角度下的自适应曝光参数 Ω_A 以及自适应重建参数 Ω_R ; 该ADMM-Net网络采用小批量随机梯度下降法对该网络进行分级训练, f_x, f_y, f_z 表示图像f在坐标点x, y, z的位置信息。

5. 根据权利要求1所述的一种病人智能监控排序方法,其特征在于,所述S2包括:

S21、构建CT伪影自动辨识的对抗主动学习网络;

S22、构建CT伪影自动校正的对抗学习网络;

所述S21包括:

基于主动学习和对抗学习理论技术进行网络研究设计; 主动学习网络能辅助数据中伪影标注, 主动学习网络 $A = (C, Q, S, L, U)$, C为机器学习模型, 用于CT伪影辨别和标识; Q为查询函数, 采用基于委员会选择算法作为查询策略, 用于从未标注样本池U中筛选含大信息量的数据; S为监督者, 选择样本U中正确的标签, 然后利用获得的新知识来训练分类器和下一轮查询;

所述S22包括:

S2201、构建伪影辨识类型索引的伪影自动校正对抗学习网络, 辨识伪影类型;

S2202、根据伪影辨识结果, 对每类伪影进行标注索引;

S2203、针对不同伪影, 采用不同的对抗网络进行自动校正;

S2204、根据伪影辨识网络中辨识结果及范围, 采用特征提取方法, 对弦图中伪影部分进行特征分析和提取, 对于不同特征构建特定的损失函数, 以实现基于伪影结构特征差异

的伪影自动校正;

S2205、对于符合预设条件的伪影,依据辨识结果,对CT投影数据进行多尺度方向场处理,提取投影数据中伪影部分多尺度方向数据信息,并根据多尺度方向数据信息设置对抗网络代价函数,获得伪影校正后的投影数据。

6.根据权利要求1所述的一种病人智能监控排序方法,其特征在于,所述S5包括:

S51、构建面向急诊病人智能监控排序的策略网络;

网络架构基于高维卷积神经网络,目的是筛选心血管急重病人CT投影数据;高维卷积神经网络最终确定图像是否包含急性心血管疾病;

S52、构建面向血管疾病辅助报告生成的深度网络得到的监控排序结果;对心血管急重病人CT投影数据优先判断,根据心血管疾病样本库,使用递归神经网络生成疾病辅助报告。

一种病人智能监控排序方法

技术领域

[0001] 本发明涉及排序领域,尤其涉及一种病人智能监控排序方法。

背景技术

[0002] 随着我国医疗水平的不断提高,在CT设备日益普及的今天,CT产品自市场化以来,一直保持着技术创新的传统,不断开发新一代产品以便开拓临床应用的新领域,产品的更新换代使原有产品发生了质的变化,具有新的功能,能满足顾客新的需要,在创造新的顾客使用功能价值的同时,也使企业保持了足够的利润。近五年来,AI技术在数据、算法和计算能力等方面日趋成熟,屡获突破,已开始真正解决实际问题,切实创造经济效益。作为大数据分布的显著代表,医疗行业有望成为应用前景最为广阔行业之一,因此其具有巨大的商业化潜力。

[0003] 因此通过人工智能技术与大规模医学CT数据的融合解决传统医疗资源不均衡的矛盾尤为必要。为此,我们推出了一种病人智能监控排序方法。

发明内容

[0004] 鉴于上述问题,本发明的目的在于提供一种病人智能监控排序方法,包括:

[0005] S1、基于深度识别模型对CT扫描协议进行自适应优化;

[0006] S2、基于对抗技术对CT伪影进行辨识与自动校正;

[0007] S3、基于增量学习技术进行CT定量成像;

[0008] S4、基于迁移学习技术对CT影像进行智能分析;

[0009] S5、对CT影像进行辅助决策。

[0010] 优选地,所述S1包括:

[0011] S11、构建脏器区域解剖特征辨识网络;

[0012] S12、构建CT个性化扫描协议任务导向网络。

[0013] 优选地,所述S11包括:

[0014] S1101、构建三维定位像成像子网络:

[0015] 包括噪声估计块,伪影估计块和图像滤波块的深度残差学习子网络,其中噪声估计块、伪影估计块和图像滤波块分别通过残差学习网络、多尺度小波和卷积神经网络进行处理;

[0016] 基于多尺度小波变换的处理流程进行伪影估计,通过迭代的方法进一步提高微剂量图像的图像质量,最终获得三维定位像;

[0017] S1102、构建脏器区域辨识子网络:

[0018] 基于深度残差学习网络输出的恢复后的微剂量三维定位图像作为辨识网络的输入;

[0019] 其中脏器区域辨识网络包含编码过程和解码过程;

[0020] 其中编码过程采用残差块的结构,解码过程采用全卷积网络;训练集被定义为X,

其中 X_i 为第 i 幅输入图像, Y_i 为第 i 幅输入图像的标签,其中 I 定义为不同的重建目标区域;同时定义 $\hat{Y}_{ik}$ 为第 i 幅输入图像的第 k 个像素的概率; $\hat{Y}_i$ 为图像水平预测的概率图,则可以通过像素水平的所有计算得到,其代价函数为:

$$[0021] \quad \begin{cases} L = - \sum_i (I(Y_i = 1) \log(\hat{Y}_{ik}) + I(Y_i = 0) \log(1 - \hat{Y}_{ik})) \\ \hat{Y}_i = \left(\frac{1}{|X_i|} \sum_{k=1}^{|X_i|} \hat{Y}_{ik}^r \right)^{1/r} \end{cases}$$

[0022] 三维定位像成像子网络和脏器区域辨识子网络通过级联得到最终的脏器区域解剖特征辨识网络, L 表示代价函数, r 表示控制参数。

[0023] 优选地,所述S12包括:

[0024] S1201、构建深度识别网络,所构建的深度识别模型是基于双向深度递归网络;

[0025] S1202、利用由脏器区域解剖特征辨识网络中获得的三维定位像和目标脏器区域,作为高维图像特征提取网络的输入,提取出三维定位像和目标脏器区域的形态学特征 $W_{patientj}^2$,纹理特征 W_{scoutj}^2 ;

[0026] S1203、个性化扫描参数估计,基于任务驱动,病人驱动的多目标优化,

[0027] 其中,所述S1203中个性化扫描参数估计的优化过程通过一个目标方程求解

$$[0028] \quad \Phi(\Omega_A, \Omega_R) = \frac{\left[\iiint W_{Taskj}^2 T_j^2(\Omega_A, \Omega_R) df_x df_y df_z \right]^2}{\iiint S_j(\Omega_A, \Omega_R) T_j^2(\Omega_A, \Omega_R) W_{Taskj}^2 df_x df_y df_z}, \text{其中 } \Omega_A \text{ 为待求解的自适应扫描}$$

参数; Ω_R 为待求解的自适应重建参数; S 表示局部噪声功率谱的估计, T 表示局部调制传递函数的估计, W_{Taskj}^2 是基于任务驱动结合病人驱动的参数估计,包含病人核心信息 $W_{patientj}^2$ 和三维定位图像高维形态学特征 $W_{patientj}^2$,纹理特征 W_{scoutj}^2 ,即 $W_{Taskj}^2 = F(W_{patientj}^2, W_{scoutj}^2)$;最后通过ADMM-Net网络优化出每个角度下的自适应曝光参数 Ω_A 以及自适应重建参数 Ω_R ;该级联网络采用小批量随机梯度下降法对该网络进行分级训练, f_x, f_y, f_z 表示图像 f 在坐标点 x, y, z 的位置信息。

[0029] 优选地,所述S2包括:

[0030] S21、构建CT伪影自动辨识的对抗主动学习网络;

[0031] S22、构建CT伪影自动校正的对抗学习网络;

[0032] 所述S21包括:

[0033] 基于主动学习和对抗学习理论技术进行网络研究设计;主动学习网络能辅助数据中伪影标注,主动学习网络 $A = (C, Q, S, L, U)$, C 为机器学习模型,用于CT伪影辨别和标识; Q 为查询函数,采用基于委员会选择算法作为查询策略,用于从未标注样本池 U 中筛选含大信息量的数据; S 为监督者,选择样本 U 中正确的标签,然后利用获得的新知识来训练分类器和下一轮查询;

[0034] 所述S22包括:

[0035] S2201、构建伪影辨识类型索引的伪影自动校正对抗学习网络,辨识伪影类型;

[0036] S2202、根据伪影辨识结果,对每类伪影进行标注索引;

[0037] S2203、针对不同伪影,采用不同的对抗网络进行自动校正;

[0038] S2204、根据伪影辨识网络中辨识结果及范围,采用特征提取方法,对弦图中伪影部分进行特征分析和提取,对于不同特征构建特定的损失函数,以实现基于伪影结构特征差异的伪影自动校正;

[0039] S2205、对于符合预设条件的伪影,依据辨识结果,对CT投影数据进行多尺度方向场处理,提取投影数据中伪影部分多尺度方向数据信息,并根据多尺度方向数据信息设置对抗网络代价函数,获得伪影校正后的投影数据。

[0040] 优选地,所述S3包括:

[0041] S31、构建低剂量CT定量成像监督学习网络:

[0042] 低剂量CT定量成像监督学习网络包含全连接滤波层、正弦反投影层以及残差卷积神经网络,其中全连接滤波层基于滤波反投影算法滤波核进行优化设计,正弦反投影层对应于滤波反投影算法中的反投影算子,残差卷积神经网络用于进一步优化重建结果,该网络代价函数设计为2范数均方根误差,记为: $E(\Theta) = \frac{1}{|N|} \sum_{i=1}^N \|\bar{x}_{H_i}(\Theta) - x_{H_i}^{ref}\|_2^2$ 其中 $\bar{x}_H$ 为CT重建网络的最终预测图像, x_H^{ref} 为目标CT图像,N为训练样本数, Θ 为需要学习的参数;

[0043] S32、构建半监督增量学习网络:将外源获取的含噪CT投影数据通过多种形变场后输入预先训练好的FBP net,对CT图像结果进行自适应加权融合,得到融合后的高质量CT目标图像,对进行FBP net参数再次深度优化,获得半监督定量成像模型;

[0044] S33、构建CT定量成像无监督增量学习网络;基于Log变换前含噪CT投影数据统计特性以及CT投影数据高阶导数稀疏性设计CT定量成像无监督增量学习网络;基于最大后验概率框架构建深度学习网络中的目标函数,其包含基于似然函数的数据保真项以及基于分段线性的先验信息项,该目标函数能够更加准确地描述CT投影数据,且能沿着梯度方向进行训练优化,其表达式为:

$$L(G, \theta) = \sum_{y_i \in C_1} \left(\sum_{j=1}^N \left(\frac{\|I_i - G_i\|_2^2}{2\sigma^2} - G_i \ln I_{0j} + G_j f_{\theta}(y_i)_j + \ln(G_j!) \right. \right. \\ \left. \left. + I_{0j} e^{f_{\theta}(y_i)_j} \right) + k \left\| \ln(D_2 f_{\theta}(y_i) + \varepsilon) \right\|_1 \right) \quad [0045]$$

[0046] 其中, C_1 表示含噪CT投影训练数据集, y_i 为第i个含噪CT投影训练数据,N表示数据集个数,G表示满足复合泊松统计特性的X射线光子数,I代表探测器接收的光子数, I_i 代表第i个探测器接收的光子数, G_i 代表 I_i 的近似中间值, $G_j!$ 表示第j个投影下G的乘值, I_{0j} 表示第j个投影下的入射光子数, ε 代表电子噪声,且服从均值为0,方差为 σ^2 的高斯分布, D_2 表示二阶差分算子, f_{θ} 代表无监督学习网络映射,其中 θ 为网络映射中需要学习的参数,利用滤波反投影算法重建得到高质量CT图像, $f_{\theta}(y_i)_j$ 代表对于第i个含噪CT投影训练数据 y_i 在像素j上无监督学习网络映射。

[0047] 优选地,所述S4包括:

[0048] S41、构建基于视频景深迁移学习技术的血管定性辨识网络,包括:

[0049] S4101、构建动态景深区域识别网络:训练集被定义为 $s = \{(x_i, y_i), i = 1, 2, 3, \dots, n\}$,其中 x_i 为第i时间帧三维序列输入图像, y_i 为第i时间帧标签数据, $\hat{y}_i$ 为网络输出结果,其

代价函数为：

$$[0050] \quad L = \frac{1}{n} \sum_{i=1}^n y_i \log \hat{y}_i + (1 - y_i) \log (1 - \hat{y}_i)$$

[0051] S4102、构建视频景深迁移学习网络；

[0052] S42、构建基于医学多模态迁移成像的血管定量识别网络，包括：

[0053] S4201、构建血管定量识别网络：训练集被定义为 $S = \{(X_i, Y_i), i = 1, 2, 3, \dots, n\}$ ，其中 X_i 为第 i 幅输入图像， $Y_i \in \{0, 1\}$ 为第 i 幅输入图像的标签，其中 $Y_i = 1$ 定义为异常图像， $Y_i = 0$ 定义为非异常图像；

[0054] 定义 $\hat{Y}_{ik}$ 为第 i 幅输入图像的第 k 个像素的概率，其中 $k = \{1, 2, 3, \dots, |X_i|\}$ ， $|X_i|$ 表示为 X_i 总的像素个数，若 $\hat{Y}_i$ 为图像水平预测的概率图，则 $\hat{Y}_i$ 通过像素水平的所有 $\hat{Y}_{ik}$ 计算得到，其代价函数为：

$$[0055] \quad \begin{cases} L_{\text{MIL}} = - \sum_i (I(Y_i = 1) \log(\hat{Y}_{ik}) + I(Y_i = 0) \log(1 - \hat{Y}_{ik})) \\ \hat{Y}_i = \left(\frac{1}{|X_i|} \sum_{k=1}^{|X_i|} \hat{Y}_{ik}^r \right)^{1/r} \end{cases}$$

[0056] 其中 $I(\cdot)$ 为指示函数， $\hat{Y}_i$ 由 Soft max Function 计算得到， r 为控制参数； L_{MIL} 表示代价函数；

[0057] S4202、构建多模态迁移学习网络。

[0058] 优选地，所述 S5 包括：

[0059] S51、构建面向急诊病人智能监控排序的策略网络；

[0060] S52、构建面向血管疾病辅助报告生成的深度网络得到的监控排序结果。

[0061] 本发明的有效果：

[0062] 1、本发明构建了一种面向急诊病人智能监控排序的策略网络，网络架构可以基于多种深度卷积网络技术，比如高维卷积神经网络，目的是筛选心血管急重病人 CT 投影数据；高维卷积神经网络最终确定图像是否包含急性心血管疾病，从而使图像按照“急重优先”顺序而非原本采集的顺序进行诊断，优化有限的医院的医疗资源，达到快速诊断和治疗“急重优先”的病人。

[0063] 2、本发明中针对临床应用中 CT 成像所面临的三大问题，结合人工智能 (AI) 技术，将各个问题纳入深度学习网络中，同时把各子网络依次递进，融为一体，目标明确，构建出面向多重任务扫描协议自适应优化，微辐射剂量 CT 定量成像，CT 成像智能辅助诊断的 CT 成像与智能分析新框架。

[0064] 3、本发明构建的 CT-AI 影像系统新框架是临床任务导向，更具有临床实际意义，且该框架基于 CT 影像扫描-重建-辅助分析一体化系统，深度分析了 CT 影像系统每个部件的潜力和需求，便于后续改造升级 CT 影像系统。

[0065] 4、本发明有效解决了当前 CT 的 CAD x 技术多基于 CT 图像，忽略了投影数据中包含的更为丰富和详尽的医疗信息；本发明的一体化框架，输出端的预测误差最终可传递到输入端的 CT 投影数据，等价于直接从投影出发，利用多角度下的投影信息进行心血管异常的

定位与识别,即从原始数据中进行预测。

附图说明

[0066] 利用附图对本发明作进一步说明,但附图中的实施例不构成对本发明的任何限制,对于本领域的普通技术人员,在不付出创造性劳动的前提下,还可以根据以下附图获得其它的附图。

[0067] 图1,为本发明一种病人智能监控排序方法的一种示例性实施例图。

具体实施方式

[0068] 下面详细描述本发明的实施例,所述实施例的示例在附图中示出,其中自始至终相同或类似的标号表示相同或类似的元件或具有相同或类似功能的元件。下面通过参考附图描述的实施例是示例性的,仅用于解释本发明,而不能理解为对本发明的限制。

[0069] 如图1所示的一种实施例,本发明提供了一种病人智能监控排序方法,包括本发明采用的技术方案如下:

[0070] 一种病人智能监控排序方法,包括如下步骤:

[0071] S1、基于深度识别模型对CT扫描协议进行自适应优化,包括:

[0072] S11构建脏器区域解剖特征辨识网络;

[0073] S12构建CT个性化扫描协议任务导向网络;

[0074] 辨识网络能够在微辐射剂量下精准估计目标脏器解剖区域,为后续CT扫描协议优化提供指引;

[0075] S2、基于对抗技术对CT伪影进行辨识与自动校正;

[0076] S3、基于增量学习技术进行CT定量成像;

[0077] S4、基于迁移学习技术对CT影像进行智能分析;

[0078] S5、对CT影像进行辅助决策。

[0079] 其中,所述S11包括如下步骤:

[0080] S1101、构建三维定位像成像子网络;包括噪声估计块,伪影估计块和图像滤波块的深度残差学习子网络,其中噪声估计、伪影估计和图像滤波分别通过残差学习网络、多尺度小波和卷积神经网络进行处理;基于多尺度小波变换的处理流程进行伪影估计,通过迭代的方法进一步提高微剂量图像的图像质量,最终获得高质量的三维定位像;

[0081] S1102、构建脏器区域辨识子网络:基于深度残差学习网络输出的恢复后的微剂量三维定位图像作为辨识网络的输入,利用基于语义的分割、辨识网络结构,以期达到像素级别的分割、辨识效果;其中脏器区域辨识网络包含编码过程和解码过程;其中编码过程采用残差块的结构,解码过程采用全卷积网络;训练集被定义为 X ,其中 X_i 为第 i 幅输入图像, Y_i 为第 i 幅输入图像的标签,其中 I 定义为不同的重建目标区域;同时定义 $\mathcal{V}_i$ 为第 i 幅输入图像的第 k 个像素的概率; $\hat{\mathcal{V}}_i$ 为图像水平预测的概率图,则可以通过像素水平的所有计算得到,其代价函数为:

$$[0082] \quad \begin{cases} L = - \sum_i (I(Y_i = 1) \log(\hat{Y}_{ik}) + I(Y_i = 0) \log(1 - \hat{Y}_{ik})) \\ \hat{Y}_i = \left(\frac{1}{|X_i|} \sum_{k=1}^{|X_i|} \hat{Y}_{ik}^r \right)^{1/r} \end{cases}$$

[0083] 三维定位像成像子网络和脏器区域辨识子网络通过级联得到最终的脏器区域解剖特征辨识网络,L表示代价函数,r表示控制参数。

[0084] S12、构建CT个性化扫描协议任务导向网络,包括如下步骤:

[0085] S1201、构建深度识别网络,快速精确的提取病人的体征信息,包括生化指标,年龄,身高等。所构建的深度识别模型是基于双向深度递归网络,其中递归网络已经在众多自然语言处理中取得了巨大成功以及广泛应用。利用双向深度递归网络结构能够高效的提取出病人核心信息($W_{patient}^2$),并且实现其二维向量化的表达,根据这些高维的体征信息可以辅助于CT自适应扫描参数的优化

[0086] S1202、利用由脏器区域解剖特征辨识网络中获得的高质量的三维定位像和目标脏器区域,作为高维图像特征提取网络的输入,提取出三维定位像和目标脏器区域的形态学特征 $W_{patient}^2$,纹理特征 W_{scout}^2 。不同于常规的自适应扫描协议只根据二维定位像进行自适应扫描协议的设定,本项目能够精确的估计出每个曝光投影的自适应扫描参数。其中高维图像特征提取网络可以由全卷积网络构成。

[0087] S1203、个性化扫描参数估计,基于任务驱动,病人驱动的多目标优化,包括扫描范围,管电流,管电压等,目的是为了降低病人辐射损伤的同时,保证重建图像质量、诊断精度。

[0088] 其中,所述S1203中个性化扫描参数估计的优化过程通过一个目标方程求解

$$\Phi(\Omega_A, \Omega_R) = \frac{\left[\iiint W_{Task_j}^2 T_j^2(\Omega_A, \Omega_R) df_x df_y df_z \right]^2}{\iiint S_j(\Omega_A, \Omega_R) T_j^2(\Omega_A, \Omega_R) W_{Task_j}^2 df_x df_y df_z}, \text{其中 } \Omega_A \text{ 为待求解的自适应扫描参数; } \Omega_R$$

为待求解的自适应重建参数;S表示局部噪声功率谱的估计,T表示局部调制传递函数的估计, $W_{Task_j}^2$ 是基于任务驱动结合病人驱动的参数估计,包含病人核心信息 $W_{patient}^2$ 和三维定位图像高维形态学特征 $W_{patient}^2$,纹理特征 W_{scout}^2 ,即 $W_{Task_j}^2 = F(W_{patient}^2, W_{scout}^2)$;最后通过ADMM-Net网络优化出每个角度下的自适应曝光参数 Ω_A 以及自适应重建参数 Ω_R ;该级联网络采用小批量随机梯度下降法对该网络进行分级训练, f_x, f_y, f_z 表示图像f在坐标点x,y,z的位置信息,网络训练的收敛性已在预实验中进行分析。

[0089] 其中,S2包括:

[0090] S21构建CT伪影自动辨识的对抗主动学习网络;

[0091] S22构建CT伪影自动校正的对抗学习网络;

[0092] S21基于主动学习和对抗学习理论技术进行网络研究设计;主动学习网络能辅助数据中伪影标注,主动学习网络 $A = (C, Q, S, L, u)$,C为机器学习模型,用于CT伪影辨别和标识;Q为查询函数,采用基于委员会选择算法作为查询策略,用于从未标注样本池U中筛选含大信息量的数据;S为监督者,选择样本U中正确的标签,然后利用获得的新知识来训练分类

器和下一轮查询;最终实现较少标识数据下的高精度CT常见伪影高辨识与精标注;

[0093] S22构建CT伪影自动校正的对抗学习网络:包括如下步骤:

[0094] S2201、构建伪影辨识类型索引的伪影自动校正对抗学习网络,辨识不同伪影类型,如金属伪影,环形伪影,风车伪影等:

[0095] S2202、根据伪影辨识结果,对每类伪影进行标注索引;

[0096] S2203、然后针对不同伪影,采用不同的对抗网络进行自动校正;

[0097] S2204、在多种伪影存在混叠情况下或不同伪影表征相似情况下,拟根据伪影辨识网络中辨识结果及范围,首先采用特征提取方法,对弦图中伪影部分进行特征分析和提取,对于不同特征我们拟构建特定的损失函数,以实现基于伪影结构特征差异的伪影自动校正;

[0098] S2105、对于符合预设条件的伪影,例如影响解剖结构准确辨识,或影响CT图像标准值的强伪影,如金属伪影,环形伪影等,依据辨识结果,对CT投影数据进行多尺度方向场处理,如多尺度方向变换场和多尺度轮廓变换场,以提取投影数据中伪影部分多尺度方向数据信息,并根据这些多尺度数据信息设计针对性的对抗网络代价函数,最终获得伪影校正后的投影数据.

[0099] 其中,所述S3包括如下步骤:

[0100] S31、构建低剂量CT定量成像监督学习网络:

[0101] 对于已有范例CT“含噪图像-目标图像”大样本数据,采用“投影域-图像域”深度滤波反投影网络估计数据对大样本内部特征,并以此作为监督学习成像网络;低剂量CT定量成像监督学习网络包含全连接滤波层、正弦反投影层以及残差卷积神经网络,其中全连接滤波层基于滤波反投影算法滤波核进行优化设计,正弦反投影层对应于滤波反投影算法中的反投影算子,残差卷积神经网络用于进一步优化重建结果,该网络代价函数设计为2范数均方根误差,记为: $E(\Theta) = \frac{1}{|N|} \sum_{i=1}^N \|\bar{x}_{H_i}(\Theta) - x_{H_i}^{ref}\|_2^2$ 其中 $\bar{x}_H$ 为CT重建网络的最终预测图像, x_H^{ref} 为目标CT图像,N为训练样本数, Θ 为需要学习的参数;

[0102] S32、构建半监督增量学习网络:本项目首先将外源获取的含噪CT投影数据通过多种形变场后输入预先训练好的FBP net,随后网络重建CT图像结果进行自适应加权融合,得到融合后的高质量CT目标图像,进而,运用不断增加的“含噪CT投影数据-目标CT图像”数据对进行FBP net参数再次深度优化,最终,完成半监督定量成像模型搭建;

[0103] S33、构建CT定量成像无监督增量学习网络;基于Log变换前含噪CT投影数据统计特性,如复合泊松-高斯噪声分布,以及CT投影数据高阶导数稀疏性设计CT定量成像无监督增量学习网络。基于最大后验概率框架,本项目设计了深度学习网络中的目标函数,其包含基于似然函数的数据保真项以及基于分段线性的先验信息项,该目标函数能够更加准确地描述CT投影数据,且能沿着梯度方向进行训练优化,其表达式为:

$$L(G, \theta) = \sum_{y_i \in C_1} \left(\sum_{j=1}^N \left(\frac{\|I_i - G_i\|_2^2}{2\sigma^2} - G_i \ln I_{0j} + G_j f_{\theta}(y_i)_j + \ln(G_j!) \right. \right. \\ \left. \left. + I_{0j} e^{f_{\theta}(y_i)_j} \right) + k \left\| \ln \left(D_2 f_{\theta}(y_i) + \varepsilon \right) \right\|_1 \right)$$

[0104]

[0105] 其中, C_1 表示含噪CT投影训练数据集, y_i 为第 i 个含噪CT投影训练数据, N 表示数据集个数, G 表示满足复合泊松统计特性的X射线光子数, I 代表探测器接收的光子数, I_i 代表第 i 个探测器接收的光子数, G_i 代表 I_i 的近似中间值, $G_j!$ 表示第 j 个投影下 G 的乘值, I_{0j} 表示第 j 个投影下的入射光子数, ε 代表电子噪声, 且服从均值为0, 方差为 σ^2 的高斯分布, D_2 表示二阶差分算子, f_θ 代表无监督学习网络映射, 其中 θ 为网络映射中需要学习的参数, 利用滤波反投影算法重建得到高质量CT图像, $f_\theta(y_i)_j$ 代表对于第 i 个测量值 y_i 在像素 j 上无监督学习网络映射;

[0106] 其中, 所述S4包括如下步骤: S41、构建基于视频景深迁移学习技术的血管定性辨识网络; 心血管灌注CT成像数据包含多个连续时间帧的图像数据, 这些数据具有高度时间连续性及空间相关性, 这些特性也同样存在于自然场景视频数据中。相比于灌注CT图像因缺乏标注数据难以直接用来训练网络, 自然视频数据具有精标签且易于用于训练网络。因此, 基于4, 本研究拟采用迁移学习技术, 将视频景深分析网络用于定量评估心血管状态

[0107] S4101、构建动态景深/区域识别网络: 训练集被定义为 $s = \{(x_i, y_i), i = 1, 2, 3, \dots, n\}$, 其中 x_i 为第 i 时间帧三维序列输入图像, y_i 为第 i 时间帧标签数据 (比如视频景深图像/CT心血管区域图像), 即二维的概率热点图 (Hot map), 能定量区分不同区域, $\hat{y}_i$ 为网络输出结果, 其代价函数为:

$$[0108] \quad L = \frac{1}{n} \sum_{i=1}^n y_i \log \hat{y}_i + (1 - y_i) \log (1 - \hat{y}_i)$$

[0109] S4102、构建视频景深迁移学习网络; 本项目首先将自然视频数据对输入上述识别网络, 进行网络预训练, 得到景深网络, 随后制定迁移学习策略, 用心血管灌注CT数据对对景深网络进行迁移学习训练得到血管区域定量评估网络, 其中评估网络中原景深网络部分参数冻结, 只训练其他层的参数, 深度挖掘心脑血管CT序列图像的高维稳健特征, 实现心血管定性辨识

[0110] S42、构建基于医学多模态迁移成像的血管定量识别网络;

[0111] 包括S4201、构建血管定量识别网络: 训练集被定义为 $S = \{(X_i, Y_i), i = 1, 2, 3, \dots, n\}$, 其中 X_i 为第 i 幅输入图像, $Y_i \in \{0, 1\}$ 为第 i 幅输入图像的标签, 其中 $Y_i = 1$ 定义为异常图像, $Y_i = 0$ 定义为非异常图像。同时定义 $\hat{Y}_{ik}$ 为第 i 幅输入图像的第 k 个像素的概率, 其中 $k = \{1, 2, 3, \dots, |X_i|\}$, $|X_i|$ 表示为 X_i 总的像素个数。如果 $\hat{Y}_i$ 为图像水平预测的概率图, 则 $\hat{Y}_i$ 可以通过像素水平的所有 $\hat{Y}_{ik}$ 计算得到, 其代价函数为:

$$[0112] \quad \begin{cases} L_{ML} = - \sum_i (I(Y_i = 1) \log(\hat{Y}_{ik}) + I(Y_i = 0) \log(1 - \hat{Y}_{ik})) \\ \hat{Y}_i = \left(\frac{1}{|X_i|} \sum_{k=1}^{|X_i|} \hat{Y}_{ik}^r \right)^{1/r} \end{cases}$$

[0113] 其中 $I(\cdot)$ 为指示函数, $\hat{Y}_i$ 由 Soft max Function 计算得到, r 为控制参数; L_{ML} 表示代价函数;

[0114] S4202、构建多模态迁移学习网络: 针对脑灌注, 首先将自然图像数据对输入上述识别网络, 进行网络预训练, 随后, 用脑灌注MRI数据对对经自然图像训练后的识别网络进

行迁移学习训练得到血管区域定量评估网络;最后,制定迁移学习策略,用脑灌注CT数据对先对脑灌注CT投影数据进行重建,再对血管区域定量评估网络进行迁移学习,融合脑部MRI,CT图像内在解剖结构相关性以及不同模态影像信息多样性,优化血管区域定量评估网络参数,其中根据脑灌注CT数据集大小及参数个数,可选择:(1)对前n层参数冻结起来,即在训练脑灌注CT血管区域定量评估网络的时候,不改变这n层的值;(2)不冻结这前n层参数,而是不断调整网络参数的值,称为微调两种策略进行迁移学习;最终,定量识别脑灌注CT图像脑卒中区域;同理,针对心肌灌注数据,首先将自然图像数据对输入上述识别网络,进行网络预训练,随后,用心肌灌注PET数据对对经自然图像训练后的识别网络进行迁移学习训练得到血管区域定量评估网络;最后,制定迁移学习策略,用心肌灌注CT数据对先对脑灌注CT投影数据进行重建,再对血管区域定量评估网络进行迁移学习,融合心肌PET,CT图像内在解剖结构相关性以及不同模态影像信息多样性,优化血管区域定量评估网络参数,其中根据心肌灌注CT数据集大小及参数个数,选择跟前面类似的两种策略进行参数训练;最终,定量识别心肌灌注CT图像心梗区域。

[0115] 其中,所述S5包括如下步骤:S51、构建面向急诊病人智能监控排序的策略网络;一种面向急诊病人智能监控排序的策略网络,网络架构可以基于多种深度卷积网络技术,比如高维卷积神经网络,目的是筛选心血管急重病人CT投影数据。高维卷积神经网络最终确定图像是否包含急性心血管疾病,从而使图像按照“急重优先”顺序而非原本采集的顺序进行诊断,优化有限的医院的医疗资源,达到快速诊断和治疗“急重优先”的病人;

[0116] S52、构建面向血管疾病辅助报告生成的深度网络得到的监控排序结果,本项目依“急重优先”最优顺序对心血管急重病人CT投影数据优先判断,根据心血管疾病样本库,拟使用递归神经网络生成疾病辅助报告。

[0117] 其中,对于CT投影数据,拟构建描述图像最大概率表达形式:

[0118] $\theta^* = \arg \max_{\theta} \sum_{I,S} \log p(S|I; \theta)$ 其中 θ 为模型参数,I是CT投影数据,S代表正确的转录,且无长度限制。通常应用链规则来模拟 $S_0, \dots, S_N$ 的联合概率,N为特定示例的长度。

[0119] $\log p(S|I) = \sum_{t=0}^N \log p(S_t|I, S_0, \dots, S_{t-1})$ 模型训练时,(S,I)构成一个训练示例对,我们使用随机梯度下降算法优化对数概率之和 $\log p(S|I)$ 。

[0120] 其中,还包括长短期记忆网络简称LSTM构建概率p;LSTM是以网络展开形式进行设计,可以为图像和每个句子创建LSTM存储器的副本,使得所有LSTM在时间上共享相同的参数,所有重复连接都转换为展开版本中的前馈连接,则展开过程如下:

[0121] $x_{-1} = \text{CNN}(I)$

[0122] $x_t = W_e S_t, t \in \{0, \dots, N-1\}$

[0123] $p_{t+1} = \text{LSTM}(x_t), t \in \{0, \dots, N-1\}$

[0124] 其中我们将每个单词表示为单热向量 S_t ,其尺寸等于字典的大小。注意,我们用两个特殊的单词 S_0 和 S_N 分别表示句子的开头和结尾。图像和单词都映射到同一个空间,图像通过使用视觉CNN,并通过单词嵌入 W_e 。图像I仅在t-1时输入一次,以通知LSTM图像内容。我们的损失函数是每个步骤中正确单词的负对数可能性的总和,可表示如下:

$$[0125] \quad L(I, S) = - \sum_{t=1}^N \log p_t(S_t)$$

[0126] 通过优化LSTM的所有参数,图像嵌入器CNN的顶层和单词嵌入 W_e 来使上式的损失函数达到最小化;该网络最终输入心血管疾病分类识别结果,用于辅助后续医疗诊断。

[0127] 本发明的有效果:

[0128] 1、本发明构建了一种面向急诊病人智能监控排序的策略网络,网络架构可以基于多种深度卷积网络技术,比如高维卷积神经网络,目的是筛选心血管急重病人CT投影数据;高维卷积神经网络最终确定图像是否包含急性心血管疾病,从而使图像按照“急重优先”顺序而非原本采集的顺序进行诊断,优化有限的医院的医疗资源,达到快速诊断和治疗“急重优先”的病人。

[0129] 2、本发明中针对临床应用中CT成像所面临的三大问题,结合人工智能(AI)技术,将各个问题纳入深度学习网络中,同时把各子网络依次递进,融为一体,目标明确,构建出面向多重任务扫描协议自适应优化,微辐射剂量CT定量成像,CT成像智能辅助诊断的CT成像与智能分析新框架。

[0130] 3、本发明构建的CT-AI影像系统新框架是临床任务导向,更具有临床实际意义,且该框架基于CT影像扫描-重建-辅助分析一体化系统,深度分析了CT影像系统每个部件的潜力和需求,便于后续改造升级CT影像系统。

[0131] 4、本发明有效解决了当前CT的CAD x技术多基于CT图像,忽略了投影数据中包含的更为丰富和详尽的医疗信息;本发明的一体化框架,输出端的预测误差最终可传递到输入端的CT投影数据,等价于直接从投影出发,利用多角度下的投影信息进行心血管异常的定位与识别,即从原始数据中进行预测。

[0132] 尽管已经示出和描述了本发明的实施例,本领域技术人员可以理解:在不脱离本发明的原理和宗旨的情况下可以对这些实施例进行多种变化、修改、替换和变形,本发明的范围由权利要求及其等同物限定。




图1