



(12) 发明专利

(10) 授权公告号 CN 111448590 B

(45) 授权公告日 2023. 08. 15

(21) 申请号 201880076660.4

(22) 申请日 2018.09.28

(65) 同一申请的已公布的文献号
申请公布号 CN 111448590 A

(43) 申请公布日 2020.07.24

(30) 优先权数据
62/564,447 2017.09.28 US

(85) PCT国际申请进入国家阶段日
2020.05.27

(86) PCT国际申请的申请数据
PCT/EP2018/076400 2018.09.28

(87) PCT国际申请的公布数据
W02019/063760 EN 2019.04.04

(73) 专利权人 皇家飞利浦有限公司
地址 荷兰艾恩德霍芬

(72) 发明人 许世昱 P·普林森 J·维格特
R·M·曼耶沙瓦尔

(74) 专利代理机构 永新专利商标代理有限公司
72002
专利代理师 刘兆君

(51) Int.Cl.
G06T 11/00 (2006.01)

(56) 对比文件
CN 106124449 A, 2016.11.16
CN 102033043 A, 2011.04.27
CN 104335247 A, 2015.02.04
CA 2849326 A1, 2013.03.28
WO 2006082557 A2, 2006.08.10

审查员 宋佳璇

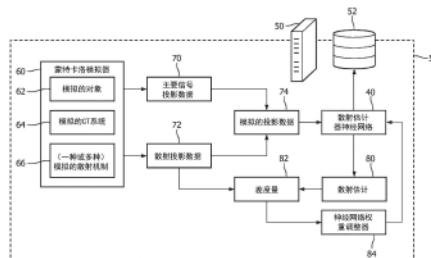

权利要求书2页 说明书11页 附图11页

(54) 发明名称

基于深度学习的散射校正

(57) 摘要

一种成像系统包括计算机断层摄影(CT)成像设备(10)(任选地谱CT)、电子处理器(16、50)和非瞬态存储介质(18、52),所述非瞬态存储介质存储在通过包括对至少一种散射机制(66)的模拟的蒙特卡洛模拟(60)生成的模拟的成像数据(74)上训练以将CT成像数据转换为投影空间中的散射估计或将未校正的重建的CT图像转换为图像空间中的散射估计的神经网络(40)。所述存储介质还存储指令,所述指令能由所述电子处理器读取和运行以重建通过所述CT成像设备采集的CT成像数据(12、14)来生成经散射校正的重建的CT图像(42)。这包括通过将所述神经网络应用于所采集的CT成像数据或应用于根据所采集的CT成像数据重建的未校正的CT图像(178)来生成散射估计(92、112、132、162、182)。



1. 一种存储指令的非瞬态存储介质,所述指令能由电子处理器(16、50)读取和运行以执行方法,所述方法包括:

重建计算机断层摄影(CT)投影数据(12、14)以生成散射校正的重建的CT图像(42);以及

通过以下操作来生成散射估计:

将所述CT投影数据输入到神经网络(90、110、130、160)中以生成投影空间中的所述散射估计(92、112、132、162),其中,所述重建包括使用投影空间中的所述散射估计来校正所述CT投影数据以生成散射校正的CT投影数据(96、116、136、166),并且重建所述散射校正的CT投影数据以生成所述散射校正的重建的CT图像;

其中,所述神经网络(40)通过神经网络训练被配置为将模拟的CT投影数据(74)变换为模拟的散射估计(80),对于所述模拟的散射估计,比较所述模拟的散射估计与所述模拟的CT投影数据的模拟的散射投影数据分量(72)的差度量(82)的值通过所述训练被最小化。

2. 根据权利要求1所述的非瞬态存储介质,其中,所述重建包括通过从所述CT投影数据减去投影空间中的所述散射估计(92、112、132、162)来校正所述CT投影数据,以生成所述散射校正的CT投影数据(96、116、136、166)。

3. 根据权利要求1所述的非瞬态存储介质,其中,所述模拟的CT投影数据通过CT成像的蒙特卡洛模拟(60)来生成,所述蒙特卡洛模拟(60)包括对产生所述模拟的CT投影数据的所述模拟的散射投影数据分量的至少一种散射机制(66)的模拟。

4. 根据权利要求1所述的非瞬态存储介质,其中,所述散射估计通过将未校正的重建的CT图像(178)输入到神经网络(180)中以生成图像空间中的所述散射估计(182)来生成,其中,所述重建包括重建所述CT投影数据(174)以生成所述未校正的重建的CT图像,并且使用图像空间中的所述散射估计来校正所述未校正的重建的CT图像以生成所述散射校正的重建的CT图像。

5. 根据权利要求4所述的非瞬态存储介质,其中,所述重建包括通过从所述未校正的重建的CT图像减去图像空间中的所述散射估计(182)来校正所述未校正的重建的CT图像(178),以生成所述散射校正的重建的CT图像。

6. 根据权利要求4所述的非瞬态存储介质,其中:

所述神经网络(180)通过神经网络训练被配置为将模拟的未校正的重建的CT图像变换为模拟的散射估计,对于所述模拟的散射估计,比较所述模拟的散射估计与所述模拟的未校正的重建的CT图像的模拟的散射图像分量的差度量的值通过所述训练被最小化;

其中,所述模拟的未校正的重建的CT图像通过对包括对产生模拟的散射投影数据的至少一种散射机制的蒙特卡洛模拟的蒙特卡洛模拟的CT成像数据的重建来生成,所述模拟的散射投影数据被重建成所述模拟的未校正的重建的CT图像的所述模拟的散射图像分量。

7. 根据权利要求1-6中的任一项所述的非瞬态存储介质,其中,所述方法还包括:

通过对采集的谱或双能量CT成像数据(12、14)的基函数分解(32)来生成所述CT投影数据(126)。

8. 根据权利要求7所述的非瞬态存储介质,其中,对所采集的谱或双能量CT成像数据(12、14)的所述基函数分解(32)产生所述CT投影数据作为水投影数据和碘投影数据(126)中的一个。

9. 根据权利要求1-6中的任一项所述的非瞬态存储介质,其中,所述方法还包括:
将所述散射校正的重建的CT图像(42)显示在能与所述电子处理器(16)操作通信的显示设备(22)上。
10. 根据权利要求1-6中的任一项所述的非瞬态存储介质,其中,所述方法还包括:
通过对从CT成像设备(10)接收的采集的CT投影数据(146)执行基于卷积或反卷积的散射校正(150)来生成所述CT投影数据(156)。
11. 根据权利要求1-6中的任一项所述的非瞬态存储介质,其中,所述神经网络(40)包括卷积神经网络(CNN)。
12. 一种方法,包括:
通过对CT成像的蒙特卡洛模拟(60)来生成模拟的计算机断层摄影(CT)成像数据(74),对CT成像的所述蒙特卡洛模拟(60)包括对产生所述模拟的CT投影数据的模拟的散射投影数据分量(72)的至少一种散射机制(66)的模拟;以及
通过以下中的一项来优化神经网络(40)以生成散射估计:
训练所述神经网络将所述模拟的CT投影数据变换为模拟的散射估计(80),对于所述模拟的散射估计,比较所述模拟的散射估计与所述模拟的CT投影数据的所述模拟的散射投影数据分量的差度量(82)的值通过所述训练被最小化;或者
重建所述模拟的CT投影数据(74)以生成模拟的未校正的重建的CT图像,所述重建包括将所述模拟的散射投影数据分量重建成所述模拟的未校正的重建的CT图像的模拟的散射图像分量,并且训练所述神经网络以将所述模拟的未校正的重建的CT图像变换为模拟的散射估计,对于所述模拟的散射估计,比较所述模拟的散射估计与所述模拟的散射图像分量的差度量的值通过所述训练被最小化。
13. 根据权利要求12所述的方法,还包括:
使用CT成像设备(10)来采集CT成像数据(12、14);
重建所述CT成像数据以生成散射校正的重建的CT图像(42),其中,所述重建包括通过所优化的神经网络(40)应用于所述CT成像数据或应用于根据所述CT成像数据生成的未校正的重建的CT图像(178)来生成针对所述CT成像数据的散射估计(92、112、132、162、182)。
14. 根据权利要求12-13中的任一项所述的方法,其中,所述神经网络(40)被优化为通过以下操作来生成所述散射估计:训练所述神经网络以将所述模拟的CT投影数据(74)变换为模拟的散射估计(80),对于所述模拟的散射估计,比较所述模拟的散射估计与所述模拟的CT投影数据的所述模拟的散射投影数据分量(72)的差度量(82)的值通过所述训练被最小化。
15. 根据权利要求12-13中的任一项所述的方法,其中,所述神经网络(40)被优化为通过以下操作来生成所述散射估计:重建所述模拟的CT投影数据(74)以生成模拟的未校正的重建的CT图像,所述重建包括将所述模拟的散射投影数据分量(72)重建成所述模拟的未校正的重建的CT图像的模拟的散射图像分量,并且训练所述神经网络以将所述模拟的未校正的重建的CT图像变换为模拟的散射估计,对于所述模拟的散射估计,比较所述模拟的散射估计与所述模拟的散射图像分量的差度量的值通过所述训练被最小化。

基于深度学习的散射校正

技术领域

[0001] 下文总体上涉及透射型计算机断层摄影(CT)成像领域、谱CT成像领域、CT图像重建领域、医学成像领域、图像重建领域、散射校正领域、以及相关的领域。

背景技术

[0002] CT成像中的图像伪影或退化的来源是能够源于CT扫描器硬件部件(诸如离焦x射线源、安装有x射线管组件的滤波器)的散射或通过成像对象中的散射。散射能够改变x射线的方向,或在非弹性散射的情况下能够改变能量,或两者。现有的散射校正方法包括卷积/反卷积技术和蒙特卡洛模拟,卷积/反卷积技术依赖于近似假设,其不能在实际成像情况下很好地适用,蒙特卡洛模拟在模拟的样本足够大的情况下能够是高度准确的,但是计算代价高。硬件方法(诸如对防散射栅格的使用)也能够减少散射,但是增加相当大的设备成本并且不能消除所有散射。

[0003] 在谱或双能量CT的情况下,散射能够是更有问题的。谱CT将探测到的x射线吸收数据处理为能量的函数以提取额外的信息。将x射线数据分解成谱分量能够以各种方式完成,诸如通过在x射线管组件中采用能量选择滤波器,或使用具有多个谱区分的探测器层的x射线探测器。后一方法的范例是可从荷兰埃因霍温的飞利浦有限公司获得的IQon™谱CT系统,其使用基于钇的闪烁体和双层谱探测器,所述双层谱探测器具有优先探测更低能量的x射线的上层和优先探测穿透上层的更高能量的x射线的下层。得到的低能量和高能量投影数据集能够被单独处理以生成相应的低能量和高能量图像。在其他方法中,这些投影数据集首先使用合适的基函数来分解以生成指示特定组织或物质的投影数据。一般来说,具有更低原子数的物质(诸如水)具有类似的低能量图像和高能量图像,而具有更高原子数的物质(诸如碘)在低能量图像与高能量图像之间具有更大的差异。这能够在分解过程中用来生成更有效地捕获某一原子数的物质的分布的有效Z图像。例如,被调谐以聚焦于碘的有效Z图像对所给予的基于碘的对比剂的摄取的更好可视化是有用的。

[0004] 由于原子数的影响是次要影响,所以相比于常规CT,谱或双能量CT通常对噪声源(特别是散射)更敏感。此外,散射量是能量相关的。在有时在谱或双能量CT中执行的非线性分解中,低能量投影数据集和高能量投影数据集中的散射能够在分解的结果中被进一步放大,并且一般,分解的谱图像对散射诱发的伪影更敏感。

[0005] 下文公开了新的且改进的系统和方法。

发明内容

[0006] 在一个公开的方面中,一种非瞬态存储介质存储能由电子处理器读取和运行以执行方法的指令。计算机断层摄影(CT)投影数据被重建以生成散射校正的重建的CT图像。散射估计被生成。在一种方法中,所述散射估计通过将所述CT投影数据输入到神经网络中以生成投影空间中的所述散射估计来生成;在该方法中,所述重建包括使用投影空间中的所述散射估计来校正所述CT投影数据以生成散射校正的CT投影数据,并且重建所述散射校正

的CT投影数据以生成所述散射校正的重建的CT图像。在另一方法中,所述散射估计通过将未校正的重建的CT图像输入到神经网络中以生成图像空间中的所述散射估计来生成;在该方法中,所述重建包括重建所述CT投影数据以生成所述未校正的重建的CT图像,并且使用图像空间中的所述散射估计来校正所述未校正的重建的CT图像以生成所述散射校正的重建的CT图像。

[0007] 在另一公开的方面中,模拟的CT成像数据通过对CT成像的蒙特卡洛模拟来生成,对CT成像的所述蒙特卡洛模拟包括对产生所述模拟的CT投影数据的模拟的散射投影数据分量的至少一种散射机制的模拟。神经网络然后被优化以生成散射估计。在一种方法中,所述优化需要训练所述神经网络以将所述模拟的CT投影数据变换为模拟的散射估计,对于所述模拟的散射估计,比较所述模拟的散射估计与所述模拟的CT投影数据的所述模拟的散射投影数据分量的差度量的值通过所述训练被最小化。在另一方法中,所述优化需要重建所述模拟的CT投影数据以生成模拟的未校正的重建的CT图像,所述重建包括将所述模拟的散射投影数据分量重建成所述模拟的未校正的重建的CT图像的模拟的散射图像分量,并且训练所述神经网络以将所述模拟的未校正的重建的CT图像变换为模拟的散射估计,对于所述模拟的散射估计,比较所述模拟的散射估计与所述模拟的散射图像分量的差度量的值通过所述训练被最小化。所述方法可以还包括使用CT成像设备来采集CT成像数据,并且重建所述CT成像数据以生成散射校正的重建的CT图像,其中,所述重建包括通过将所优化的神经网络应用于所述CT成像数据或应用于根据所述CT成像数据生成的未校正的重建的CT图像来生成针对所述CT成像数据的散射估计。

[0008] 在另一公开的方面中,一种成像系统包括CT成像设备(任选地谱CT成像设备)、电子处理器和非瞬态存储介质,所述非瞬态存储介质存储至少一个神经网络,所述至少一个神经网络在通过包括对至少一种散射机制的模拟的蒙特卡洛模拟生成的模拟的成像数据上训练,以将CT成像数据转换为投影空间中的散射估计或将未校正的重建的CT图像转换为图像空间中的散射估计。所述存储介质还存储指令,所述指令能由所述电子处理器读取和运行以重建通过所述CT成像设备采集的CT成像数据来生成散射校正的重建的CT图像。所述重建包括通过将所述至少一个神经网络应用于所采集的CT成像数据或应用于根据所采集的CT成像数据生成的未校正的重建的CT图像来生成散射估计。

[0009] 一个优点在于CT成像中的更准确的散射校正。

[0010] 另一优点在于CT成像中的更计算高效的散射校正。

[0011] 另一优点在于更准确地考虑分解的谱图像中的放大的散射的CT成像中的散射校正。

[0012] 另一优点在于提供容易地针对特定的CT扫描器配置(例如x射线滤波器的选择)和患者的详情或其他成像对象(例如围长、尺寸)进行调谐的CT成像中的散射校正。

[0013] 另一优点在于提供谱图像中的放大的散射以计算高效的方式被容易地考虑的谱或双能量CT成像中的散射校正。

[0014] 给定的实施例可以提供前述优点中的零个、一个、两个或全部,并且/或者可以提供在阅读并理解本公开后对本领域普通技术人员来说将变得显而易见的其他优点。

附图说明

[0015] 本发明可以采取各种部件和部件的布置以及各种步骤和步骤的安排的形式。附图仅出于说明优选的实施例的目的并且不应被解释为对本发明的限制。

[0016] 图1图解性地图示了包括如本文中公开的散射校正的谱CT成像系统。

[0017] 图2图解性地图示了用于构建用于在图1的谱CT成像系统的散射校正中使用的散射估计器神经网络的设备和方法。

[0018] 图3、图4和图5图解性地示出了图1的谱CT成像系统能够通过其执行包括在投影域中使用一个或多个散射估计器神经网络执行的散射校正的CT图像重建的各种方法。

[0019] 图6图解性地示出了图1的谱CT成像系统能够通过其执行包括在投影域中使用卷积散射校正紧接着使用散射估计器神经网络的残余散射校正的组合执行的散射校正的CT图像重建的方法。

[0020] 图7图解性地示出了图1的谱CT成像系统能够通过其执行包括在图像域中使用散射估计器神经网络执行的散射校正的CT图像重建的方法。

[0021] 图8-11呈现了如本文中描述的测试结果。

具体实施方式

[0022] 在本文中公开的用于散射校正的方法中,深度残余学习基于本文中公开的笔形射束的散射分布能够根据其对应的空气标准化的 (air-normalized) 原始信号 (主要加散射) 和周围区域中的信号来确定的见解而被采用。因此,为了训练神经网络以生成散射估计,输入合适地为具有空气标准化的原始信号的投影,并且其标签是在蒙特卡洛模拟中计算的对应的散射信号。深度残余学习是检测负责且大含量的信号中的小信号的模式的学习框架。在一些说明性实施例中,神经网络被设计有具有足够接受区域的17个层,但是这仅仅是非限制性说明性范例。所公开的方法利用其中神经网络从大且复杂的原始信号学习小偏移散射信号的残余学习框架。蒙特卡洛模拟被用来生成训练数据。蒙特卡洛模拟对主要CT投影进行模拟,并且对一种或多种散射机制进行模拟,相应地,完整的模拟CT投影数据集被生成,其中散射分量是可识别的,因为它通过对(一种或多种)散射机制的模拟来生成。因此,完整的模拟CT投影数据集充当训练输入,并且已知的散射分量实现神经网络的输出的准确性的评价,例如通过比较模拟的散射估计(即神经网络的输出)与蒙特卡洛模拟的CT投影数据的模拟的散射投影数据分量的差度量来测量。训练调整神经网络的权重或其他参数以最小化该差度量的值。

[0023] 参考图1,说明性计算机断层摄影(CT)成像系统包括CT成像设备10,在说明性范例中,该CT成像设备是采集低能量CT投影数据12和高能量CT投影数据14的谱CT成像设备。例如,CT成像设备10可以是可从飞利浦有限公司获得的IQon™谱CT设备。IQon™谱CT使用基于钷的闪烁体和双层谱探测器,所述双层谱探测器具有优先探测更低能量的x射线由此收集低能量投影数据12的上层和优先探测穿透上层的更高能量的x射线由此收集高能量投影数据14的下层。其他谱CT数据采集技术能够被采用,例如使用通过滤波器等方式对x射线管组件的谱调制。此外,虽然谱CT对散射的更高敏感性实现谱CT中的特定值的所公开的方法,但是所公开的用于散射校正的方法也被容易地应用于也受未校正的散射不利地影响的常规(即非谱)CT。还应当注意,所公开的散射校正方法可结合散射减轻技术(诸如对防散射栅格

的使用、对其他散射校正算法(诸如基于卷积或反卷积的散射校正)的使用等等)来使用。

[0024] CT成像数据(例如说明性低能量CT投影数据12和/或高能量CT投影数据14)通过说明性计算机16的电子处理器16(诸如微处理器和辅助部件(例如存储器、数学协同处理器、ASIC电路等等))来重建,该电子处理器读取并运行非瞬态存储介质18上存储的指令以执行说明性图像重建方法20。更一般地,电子处理器16可以通过台式计算机、服务器计算机、被可操作地连接以形成计算集群的多个服务器计算机、ad hoc云计算资源等等来体现。非瞬态存储介质18可以例如以各种方式被体现为以下中的一个或多个:硬盘驱动器或其他磁性存储介质;闪存存储器、固态驱动器(SSD)、或其他电子存储介质;光盘或其他光学存储介质;其各种组合;等等。非瞬态存储介质18可以与计算机16集成在一起,例如作为内置内部硬盘驱动器,和/或可以被外部地或远程地定位,例如被体现为基于网络的服务器存储设备(诸如RAID)。说明性计算机16包括用于显示重建的CT图像的显示器22和一个或多个用户输入设备(诸如说明性键盘24、鼠标或触控板26等等)。在一些实施例中,计算机16或其他电子处理器充当用于操作CT成像设备10的电子控制器或主计算机。

[0025] 继续参考图1,说明性图像重建方法20执行谱CT图像重建过程30。这包括将基函数分解应用于低能量CT投影数据12和/或高能量CT投影数据14以生成用于重建的CT投影数据集。通过说明,基函数分解32可以被应用以生成更有效地捕获针对某一原子数的物质预期的投影的分布的有效ZCT投影数据集。例如,被调谐以聚焦于碘的有效ZCT投影数据集可以被生成,其对所给予的基于碘的对比剂的摄取的更好可视化是有用的。同样地,被调谐以聚焦于水的有效ZCT投影数据集可以被生成,其对一般解剖背景的可视化是有用的。得到的碘图像和水图像能够被熟练的放射科医生或其他医学专业人员用来阐明比能够从根据未谱求解的投影数据重建的图像获得的实质上更多的临床信息。在其他应用中,预见到重建仅由低能量CT投影数据12组成的CT投影数据集,或重建仅由高能量CT投影数据14组成的CT投影数据集,或重建由低能量CT投影数据12和高能量CT投影数据14的组合组成的CT投影数据集,等等。在非谱CT成像设备的情况下,所收集的CT投影数据一般在整体上被重建而无需任何谱分解。

[0026] 选择的CT投影数据(例如被选择作为低能量数据集12或高能量数据集14中的一个,或作为组合的数据集12、14,或作为通过基函数分解32生成的数据集,等等)通过CT图像重建30来重建,该CT图像重建可以采用任何合适的重建算法,诸如滤波反投影(FBP)、迭代正向-反向投影重建过程、基于最大似然(ML)估计的算法(诸如最大似然期望最大化(ML-EM)、有序子集期望最大化(OSEM)、等等)。为了校正散射,散射估计器神经网络40被应用以生成在散射校正中使用的散射估计。取决于其设计,散射估计器神经网络40可以被应用于CT投影数据,即,在投影域中,以生成投影域中的散射估计。该估计然后被应用以校正CT投影数据,并且因此校正的CT投影数据被重建以生成散射校正的CT图像。备选地,散射估计器神经网络40可以被设计为在图像重建之后被应用于未校正的重建的CT图像,即,在图像域中,以生成用来校正未校正的重建的CT图像以生成散射校正的重建的CT图像的图像域中的散射估计。

[0027] 对散射估计器神经网络40的使用具有许多优点。如本文中公开的,它在通过蒙特卡洛模拟生成的训练数据上被适当地离线训练,因此,它提供可与通过蒙特卡洛模拟实现的散射校正相比的高准确性散射校正,但是具有可通过训练的神经网络(诸如训练的卷积

神经网络(CNN))实现的高(在线)计算效率。因此,所公开的方法提供了既快速(即计算上高效)又准确的散射校正。此外,直截了当的是在不同的蒙特卡洛模拟上训练多个不同的散射估计器神经网络以便生成被调谐为向不同解剖尺寸或体重(例如不同围长)的人类对象提供准确散射校正的散射估计器神经网络,和/或生成被调谐为通过可安装在CT成像设备10的x射线管组件上的不同滤波器提供用于散射的准确散射校正的散射估计器神经网络,等等。这些不同的散射机制或特性能够通过采用在最类似的蒙特卡洛模拟上训练的网络作为散射估计器神经网络40而被容易地适应,并且此外,新的情况(例如新购买的滤波器、考古木乃伊或不能通过已经在医学患者上进行训练的现有散射估计器神经网络被很好地表示的一些其他成像对象的成像)能够通过针对新的情况执行蒙特卡洛模拟并且训练合适的散射估计器神经网络来适应。更进一步地,直截了当的是通过相继地应用适当的散射估计器神经网络来考虑不同的散射机制,例如一个网络可以被训练为生成针对x射线管滤波器的散射估计,并且另一个网络可以被训练为生成针对患者的散射估计,并且这些可以被相继地应用以生成包括由于滤波器和患者散射机制两者的散射的总散射估计。

[0028] 得到的散射校正的重建的CT图像42被合适地显示在计算机16的显示器22上,和/或被存储在影像归档与通信系统(PACS)或其他存储设备或存储库中,和/或以其他方式被利用。

[0029] 参考图2,描述了用于训练散射估计器神经网络40的合适方法。训练采用计算密集型蒙特卡洛模拟,并且因此优选地被离线执行,即,远在得到的训练的散射估计器神经网络40用来执行针对实际临床CT投影数据的散射校正之前。在一些实施例中,训练可以由CT成像设备10的供应商来执行,并且得到的散射估计器神经网络40可以作为包括CT成像设备10的商用CT成像系统的部件被供应在光盘或其他非瞬态存储介质上。鉴于训练的计算复杂性,在说明性实施例中,训练由读取并运行存储在非瞬态存储介质52上的指令以执行说明性神经网络训练过程54的服务器计算机50来执行。更一般地,电子处理器50可以通过台式计算机(可能与图1中的执行具有散射校正的图像重建的计算机相同的计算机16)、说明性服务器计算机、被可操作地连接以形成计算集群的多个服务器计算机、ad hoc云计算资源、等等来体现。非瞬态存储介质50可以与图1的非瞬态存储介质18相同,和/或可以是一些其他硬盘驱动器或其他磁性存储介质、闪存存储器、SSD或其他电子存储介质、光学存储介质、其各种组合、等等。

[0030] 继续参考图2,蒙特卡洛模拟器60使用模拟的CT系统64并且包括一种或多种模拟的散射机制66对模拟的对象62的CT成像进行模拟。蒙特卡洛模拟是其中重复的统计采样用来生成模拟的事件分布的已知技术。在本情况下,模拟的事件是透射的x射线,并且每个x射线可以以一定(一般是空间相关的)吸收概率(因此,模拟的对象62的该方面可以使用对象的吸收或衰减图来表示,可能从对象的实际CT图像产生的吸收或衰减图)被吸收在模拟的对象62的任何部分中。优选地,模拟的CT成像对象62是可能使用CT成像设备10来成像的对象(例如患者)的密切近似。任选地,参考图2描述的神经网络训练能够使用针对不同类型的对象(例如不同的围长、身高等等)和/或针对不同的被成像区域的蒙特卡洛模拟数据来重复,以便提供用于训练神经网络来估计散射的足够准确的模拟数据。模拟的CT系统64提供模拟的x射线的几何形状(例如模拟的x射线事件在方向的分布上根据x射线的分布以扇形射束、锥形射束或正被模拟的其他x射线射束方式进行模拟)和到x射线探测器阵列的距离

以及对探测器敏感性和其他CT成像设备特性的模拟。优选地,模拟的CT系统64是要针对其估计散射的实际CT成像设备10的密切近似。

[0031] 蒙特卡洛模拟器60还模拟一种或多种散射机制66。该方面可以与模拟的对象62和/或模拟的CT成像设备64是一体的。例如,成像对象中的散射的散射机制可以与模拟的对象62是一体的,例如通过建模(除了空间相关的吸收概率之外)x射线将被散射的(同样空间相关的)概率,并且如果这样的话,散射的x射线方向的分布和(在非弹性散射的情况下)在散射之后的x射线能量的分布。作为另一范例,被安装在x射线管组件中的滤波器中的散射的散射机制可以与模拟的CT设备64是一体的,例如通过建模x射线将会在滤波器处被散射的概率,并且如果这样的话,散射的x射线方向的分布和(在非弹性散射的情况下)在滤波器处散射之后的x射线能量的分布。各种散射机制的建模能够采用任何基本原理和/或经验散射模拟用于散射的x射线方向和能量分布。

[0032] 继续参考图2,蒙特卡洛模拟器的输出是一组模拟事件,在这种情况下是一组模拟的x射线事件。应当注意,每个模拟的x射线不必对应于单个模拟的x射线光子,但是它可以如此对应。更一般地,然而,模拟的x射线可以是x射线能量的离散单位或足够分辨率的通量,以在足够分辨率用于散射估计的情况下生成样本的最终分布。每个x射线(例如,每个x射线光子、或每个x射线通量单位、或每个x射线能量单位、等等)被个体地模拟,并且可以或可以不以如通过(一种或多种)模拟的散射机制66定义的概率经历散射。对每个x射线的模拟具有确定性结果(例如散射的或非散射的),并且散射的/非散射的事件的统计分布通过这些模拟的确定性结果的分布来捕获。有利地,每个模拟的x射线已知为非散射的x射线或散射的x射线,并且因此模拟的x射线能够被分组成(1)包含未被散射的那些模拟的事件(x射线)的主要信号投影数据集70,以及(2)包含确实经历散射事件的那些模拟的事件(x射线)的散射投影数据集72。(显著数量的光子可以经历多次散射事件。在变体实施例中,更准确的蒙特卡洛模拟保持对x射线被散射的次数的跟踪)。事件变成非散射的70或散射的72的这种分离构成可用于蒙特卡洛模拟中的信息,其不可用于实际测量的投影数据(例如通过图1中的CT成像设备10采集的低能量投影数据12或高能量投影数据14)。将非散射的投影数据70与散射的投影数据72进行组合的组合的模拟投影数据集74表示通过实际CT成像数据收集过程获得的实际更少的了解。

[0033] 用于训练散射估计器神经网络40的训练过程使用模拟的投影数据74和散射投影数据分量72。目的是训练神经网络40以将模拟的CT投影数据74变换为模拟的散射估计80,对于该模拟的散射估计,比较模拟的散射估计80与模拟的CT投影数据74的模拟的散射投影数据分量72的差度量82通过训练被最小化。在训练的每次迭代中,模拟的投影数据74被输入到神经网络40以生成模拟的散射估计80。差度量82被应用以计算比较当前迭代的模拟的散射估计80与模拟的CT投影数据74的模拟的散射投影数据分量72的差度量82的值。该差确定神经网络40正在多么好地操作以生成散射估计。神经网络权重调整器84应用任何合适的神经网络更新过程,诸如采用反向传播来计算差度量82的梯度的梯度下降优化算法,以便计算用于神经网络40的更新的权重。该过程迭代地重复直至满足停止准则,诸如(在一些说明性范例中)差度量82的值降至停止阈值之下,或差度量82的值的迭代间变化降至停止阈值之下,等等。最终的训练的散射估计器神经网络40(包括优化的神经网络权重)被存储在数据存储设备52中和/或被传输到数据存储设备18(参见图1)以用于在实际采集的CT投影

数据的散射校正中使用。

[0034] 图2中示出的说明性散射估计器神经网络训练采用蒙特卡洛模拟来生成包括可分开的主要数据分量70和散射数据分量72的模拟的CT投影数据74。更一般地,预见到生成用于训练的模拟的CT投影数据的其他方法,诸如核方法或线性泊松-玻尔兹曼方程(LPBE)求解器。

[0035] 参考图3-5,描述了使用散射估计器神经网络40的谱CT图像重建的一些说明性范例。在每个范例中,应理解,所采用的散射估计器神经网络40针对正被重建的特定类型的谱CT数据来训练。例如,如图3中示出的,低能量投影数据12被输入到已经按照图2的过程使用蒙特卡洛模拟的低能量投影数据(其中模拟的CT系统64是IQonTM谱CT并且仅模拟上或低能量x射线探测器层的输出)进行训练的低能量散射估计器卷积神经网络(CNN)90,以产生低能量散射估计92。在差操作94处,从低能量投影数据12减去低能量散射估计92以生成散射补偿的低能量投影数据96。图像重建98(诸如滤波反投影、迭代正向-反向重建过程、等等)被应用于散射补偿的低能量投影数据96,以生成散射校正的重建的低能量CT图像100。

[0036] 参考图4,高能量投影数据14被输入到已经按照图2的过程使用蒙特卡洛模拟的高能量投影数据(其中模拟的CT系统64是IQonTM谱CT并且仅模拟下或高能量x射线探测器层的输出)进行训练的高能量散射估计器CNN110,以产生高能量散射估计112。在差操作114处,从高能量投影数据14减去高能量散射估计112以生成散射补偿的高能量投影数据116。图像重建118(诸如滤波反投影、迭代正向-反向重建过程等等)被应用于散射补偿的高能量投影数据116,以生成散射校正的重建的高能量CT图像120。

[0037] 代替如图3和图4中图示的产生低能量能量图像100和高能量图像120,在其他实施例中,散射补偿的低能量投影数据集96和高能量投影数据集116可以用来生成用于谱图像重建的分解的投影,例如通过将低能量投影数据集96和高能量投影数据集116输入到适于期望的谱图像(例如水图像、碘图像等等)的基函数分解32(参见图1)中。

[0038] 参考图5,示出了用于散射校正的碘图像的重建的另一方法,其中基函数分解32在基于CNN的散射校正之前被应用。低能量投影数据12和高能量投影数据14被输入到适当的基函数分解32以生成碘投影数据126,该碘投影数据被输入到已经按照图2的过程使用蒙特卡洛模拟的碘投影数据(其中模拟的CT系统64是IQonTM谱CT并且模拟两个探测器层的输出并应用适当的基函数分解32来生成模拟的碘投影数据)进行训练的碘散射估计器CNN130,以产生碘散射估计132。在差操作134处,从碘投影数据126减去碘散射估计132以生成散射补偿的碘投影数据136。图像重建138(诸如滤波反投影、迭代正向-反向重建过程等等)被应用于散射补偿的碘投影数据136,以生成散射校正的重建的碘CT图像140。

[0039] 虽然图5的实施例操作用于产生碘图像,但是类似的处理可以用来产生另一谱分解的散射校正的重建的CT图像(诸如水图像)。为了这样做,适当的基函数分解32被应用,并且已经按照图2的过程使用期望的(例如水)分解的蒙特卡洛模拟的投影数据进行训练的散射估计器CNN被用来产生针对期望的分解的散射估计。

[0040] 在图3-5的范例中,适当的训练的散射估计器神经网络40(例如低能量散射估计器CNN90、高能量散射估计器CNN110或碘散射估计器CNN130)执行整个散射校正。在其他实施例中,适当的训练的散射估计器神经网络可以结合一些其他散射校正来采用。

[0041] 参考图6,作为此的范例,选择的投影数据146(例如说明性投影数据集12、14中的

一个或分解的投影数据集(诸如碘投影数据集126))最初通过基于卷积的散射校正150(或,在另一实施例中,基于反卷积的散射校正,或更一般地,任何类型的散射校正)来处理,以产生散射估计152。在差操作154处,从选择的投影数据146减去基于卷积的散射估计152以生成卷积校正的投影数据156。残余散射估计器CNN160然后被应用于卷积校正的投影数据156以生成残余散射估计162。在第二差操作164处,从卷积校正的投影数据156减去残余散射估计162以生成更充分散射补偿的投影数据166。图像重建168(诸如滤波反投影、迭代正向-反向重建过程等等)被应用于更充分散射补偿的投影数据166,以生成(更充分)散射校正的重建的CT图像170。在该范例中,残余散射估计器CNN160已经按照图2的过程使用蒙特卡洛模拟的卷积校正的投影数据(例如其中模拟的CT系统64的输出通过基于卷积的散射校正150来处理以生成模拟的卷积校正的投影数据)进行训练。

[0042] 在图3-6的范例中,适当的训练的散射估计器神经网络40被应用于投影空间中,即,被应用于投影数据,以生成投影空间中的散射估计。备选地,适当的训练的散射估计器神经网络能够被应用于图像空间中,即,被应用于未校正的重建的CT图像,以生成图像空间中的散射估计,然后从未校正的重建的CT图像减去该图像空间中的散射估计以产生散射校正的重建的CT图像。

[0043] 参考图7,在前述内容的说明性范例中,选择的投影数据174(例如说明性投影数据集12、14中的一个或分解的投影数据集(诸如碘投影数据集126))通过图像重建176(诸如滤波反投影、迭代正向-反向重建过程等等)来处理,以生成未校正的重建的CT图像178(即,未针对散射进行校正)。图像域散射估计器CNN180被应用于未校正的重建的CT图像178,以生成图像域散射估计182,即,图像空间中的散射估计。在差操作184处,从未校正的重建的CT图像178减去图像域散射估计182以生成对应于选择的投影数据174的散射补偿的重建的CT图像186。在这种情况下,图像域散射估计器CNN180按照图2进行训练,除了充当用于训练的输入(即,对应于图2的模拟的投影数据74)的模拟的数据是根据模拟的投影数据74重建的模拟未校正的重建的图像,其中所述重建包括将模拟的散射投影数据分量72重建成模拟的未校正的重建的CT图像的模拟的散射图像分量。图像域散射估计器神经网络180然后被训练以将模拟的未校正的重建的CT图像变换为图像域中的模拟的散射估计,对于该模拟的散射估计,比较图像域中的模拟的散射估计与模拟的散射图像分量的差度量的值通过训练被最小化。

[0044] 换言之,图像域散射估计器CNN180通过神经网络训练被配置为将模拟的未校正的重建的CT图像变换为模拟的散射估计,对于该模拟的散射估计,比较模拟的散射估计与模拟的未校正的重建的CT图像的模拟的散射图像分量的差度量的值通过训练被最小化。在该方法中,模拟的未校正的重建的CT图像通过包括对产生模拟的散射投影数据的至少一种散射机制的蒙特卡洛模拟的蒙特卡洛模拟的CT成像数据的重建来生成,所述模拟的散射投影数据被重建成模拟的未校正的重建的CT图像的模拟的散射图像分量。

[0045] 返回参考图2,如果存在要被校正的两种不同的散射机制(例如成像对象中的散射和被安装在x射线管组件中的滤波器中的散射),则这能够以两种方式被处理。在一种方法中,两种散射机制被包括在模拟的散射机制66中,并且单个蒙特卡洛模拟生成包括散射投影分量72的模拟的投影数据74,该散射投影分量包括由于两种模拟的散射机制的散射事件。得到的(单个)训练的散射估计器神经网络然后将估计通过两种散射机制产生的组合的

散射。在变体方法中,蒙特卡洛模拟被运行两次,针对每种散射机制一次。这产生两个散射估计器神经网络。对于说明性范例,这些散射估计器神经网络中的一个估计成像对象散射,而另一个散射估计器神经网络估计滤波器中的散射。在这种情况下,表示两种不同的散射机制的两个不同的散射估计器神经网络能够被顺序地应用,其中每个按照图2的训练方法在通过包括对不同散射机制的模拟的蒙特卡洛模拟生成的不同的模拟的成像数据上进行训练。虽然该后一方法需要更多的模拟时间,但是它能够在创建模块化散射校正系统方面具有优点。例如,如果谱CT设备10具有例如出于不同的目的能安装在x射线管组件上的两个或更多个不同的滤波器,那么单独的散射估计神经网络能够针对每个这样的滤波器进行训练。如果两个滤波器被组合地使用,则通过两个滤波器的总散射能够通过一个接一个地应用对应的训练的散射估计器神经网络来确定。同样地,不同的散射估计器神经网络能够针对不同类型的成像对象(例如成人、儿童、正常体重、肥胖等等)进行训练,并且适当的对象散射估计器神经网络可以连同适当的滤波器散射估计神经网络(如果滤波器被采用的话)一起被采用。这种模块性在使散射校正适合特定CT成像对象和用于在特定CT检查中使用的CT成像设备配置方面提供了很大的灵活性。

[0046] 在下文中,描述了一些另外的说明性范例。

[0047] 说明性散射估计器神经网络是基于VGG网络的CNN(Simonyan等人的“Very deep convolutional networks for large-scale imagerecognition”, arXiv Prepr. arXiv1409.1556,1409),并且神经网络的深度是基于所需的接受域来设置。对于模型建模,残余学习公式被采用,并且包含有用于快速训练的批标准化和改进的性能。在说明性范例中,卷积滤波器的大小被设置为 3×3 ,其中所有池化层都被移除。因此,具有深度d的CNN的接受域为 $(2d+1) \times (2d+1)$ 。每个投影的尺寸从 672×64 被下采样到 168×16 。这里,168是沿着X方向的重重新调节的x射线探测器行的数量,并且16是沿着Z方向的重重新调节的切片的数量。对于目标谱CT系统,防散射栅格仅沿着X方向进行放置。因此,合理的是假设,一个(重新采样的)探测器像素中的散射信号与沿着所有16个探测器行在Z上的信号相关,其中没有防散射栅格存在,并且仅有限数量的相邻探测器切片沿着X。基于实验,值32被选择。在说明性范例中,d=17被设置,并且具有尺寸 168×16 的每个投影被分成具有尺寸 32×16 的许多小块。CNN中的17个卷积层中的第一个由大小为 3×3 的64个滤波器组成,层2-16每个由大小微 $3 \times 3 \times 64$ 的64个滤波器组成,并且最后一层由大小为 $3 \times 3 \times 64$ 的单个滤波器组成。除了最后一层,每个卷积层紧随有批标准化和校正线性单元(ReLU),所述批标准化被包括以加快训练以及提升性能(参见Zhang等人的“Beyond a Gaussian Denoiser:Residual Learning of Deep CNN for Image Denoising”, pp.1-13,2016),所述校正线性单元用来引入非线性。零填充在每个卷积层中被执行以维持正确的数据维度。

[0048] 到CNN的输入(被表示为r)是具有额外的散射(s)的空气标准化的主要信号(p),即, $r=p+s$ 。残余学习公式用来训练残余映射 $T(r) \sim s$,期望的信号 $p=r-T(r)$ 根据所述残余映射来确定。CNN参数通过最小化以下距离函数来估计:

$$[0049] \quad d(w) = \sum_j \left(\|T(r;w)_j - s_j\|_2^2 + \lambda_1 \|\nabla T(r;w)_j\|_1 \right) + \lambda_2 \sum_k \|w_k\|_2^2$$

[0050] 其中w是所有层的所有权重的集合,并且 $k=1, \dots, 17$ 表示层索引。正则化项鼓励平

滑的散射信号和小的网络核。在测试中,正则化参数 $\lambda_1 = \lambda_2 = 10^{-3}$ 被使用。这里, $\{(r_j, s_j)\}_{j=1}^N$ 表示散射的原始信号和仅散射信号的N个训练对,其中j是训练单元的索引。训练集从蒙特卡洛模拟获得。

[0051] 距离(即损失)函数的最小化通过使用利用随机梯度下降(SGD)的常规误差反向传播来执行。在SGD中,初始学习速率被设置为0.01,并且训练速率被连续降至 10^{-5} 。大小为十的迷你批(Mini-batch)被使用,指示十个随机选择的数据集被用作用于训练的批。该方法在MATLAB™中使用MatConvNet工具箱来实施。基于模型的蒙特卡洛模拟被用来生成训练集。模拟的几何形状设置和参数被选择以模仿具有双层探测器的飞利浦iQon™系统的特性。顶层是低能量探测器,并且底层是高能量探测器。

[0052] 训练集通过蒙特卡洛模拟被产生如下。模拟利用120kVp的(模拟)管电压被执行。三个模体被模拟:30cm直径圆柱形水模体、肝模体和肥胖模体。对于每个模拟的模体,主要信号使用360度的完全旋转内的600个(肥胖和肝)或2400个(水)投影来分析地确定。散射数据通过在完全旋转内模拟60个投影来收集,其中每个投影具有 5×10^8 个(水和肝)或 4.5×10^9 个(肥胖)光子。由于昂贵的计算,有限数量的六个代表性扫描用来生成训练集:针对水模体和肥胖模体各一个,并且针对在模体沿头-尾方向的不同移位处的肝模体四个。数据被分成通过沿着X方向简单地翻转而被增强的大小为 32×16 的块。网络单独针对低能量层和高能量层进行训练。针对每个层的总训练时间在具有TitanXGPU的戴尔T7600工作站上为大约六个小时。

[0053] 测试集如下被创建。为了测量,与上面相同的(模拟的)肝模体被使用,但是在未用于训练的头尾移位处。30cm水圆柱体也被使用,但是该时间实际上在飞利浦iQon™系统上被扫描,而非模拟的。散射通过分别将训练的网络应用于低能量信号和高能量信号来估计。散射校正通过从每层的原始数据减去对应的散射估计来执行。校正的高投影数据和低投影数据然后被进一步分解成能量无关的基函数,诸如碘和水。这些被重建成图像空间中的基函数。单色图像被构建为基函数的线性组合。

[0054] 参考图8,对于模拟的数据,在三个不同视图的中心切片处来自CNN的散射轮廓被绘制,并且与来自针对两个探测器层的蒙特卡洛模拟(其充当地面真值)的那些进行比较。如能够在图8中看出的,CNN散射估计与来自蒙特卡洛模拟的地面真值之间的匹配是非常接近的。

[0055] 参考图9,在应用基于CNN的散射校正之后,60keV、80keV、100keV和120keV处的单色图像([-50,50])被重建,并且与从重建主要信号获得的单色图像进行比较。图9中的图像的顶行示出了主要单色图像(其充当地面真值,因为这些图像根据没有散射分量的蒙特卡洛模拟的主要CT信号来重建),图9中的图像的中间行示出了CNN校正的单色图像(即,组合的主要数据和散射数据两者被重建,并且CNN用来生成被减去的散射估计),并且图像的底行示出了差图像。

[0056] 参考图10和图11,对于实际采集的水模体CT投影数据的散射校正的图像重建,在图10中示出了来自60keV的单色图像,并且在图11中示出了色散曲线,两者与没有散射校正的结果进行比较。在图10中,图像的顶行示出了60keV、80keV、100keV和120keV处的CNN校正的单色图像([-5050]);而图像的底行在底部上示出了没有散射校正的对应的单色图像([-

5050]))。图11中示出的色散曲线通过针对每个keV确定水模体中的平均亨氏单位(HU)值来绘制,预期到对于跨过keV的水,所述色散曲线在零处是平坦的。针对每个投影估计散射的计算时间在启用了图形处理单元(GPU)的工作站上为大约6-7ms。

[0057] 已经参考优选实施例描述了本发明。他人在阅读和理解以上具体实施方式的情况下可能想到修改和更改。本文旨在将本发明解释为包括所有这种修改和更改,只要它们落入随附权利要求书及其等价方案的范围之内。




图1




图2

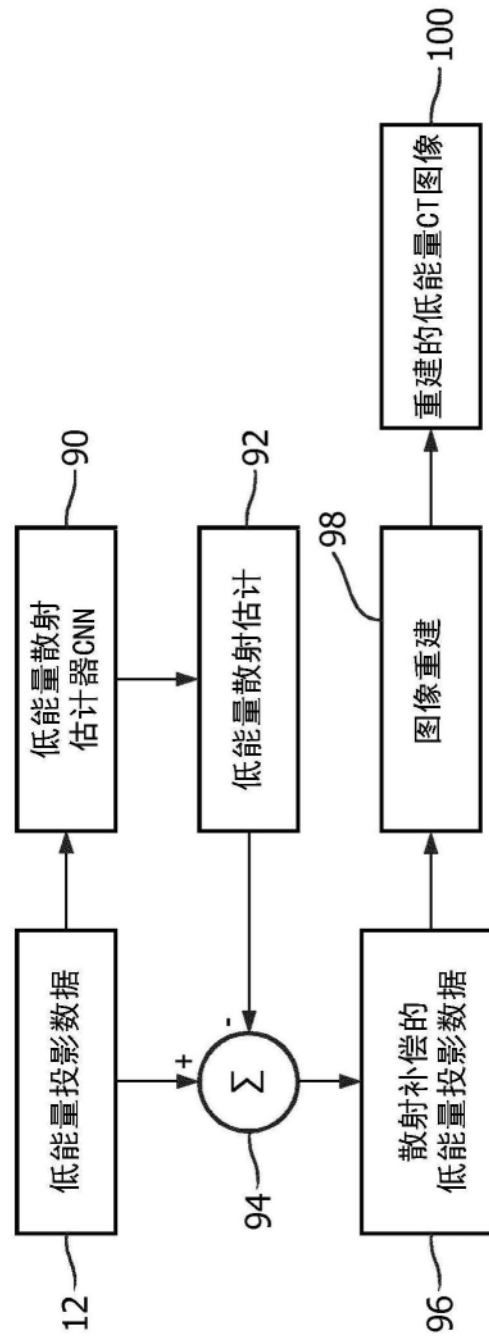


图3

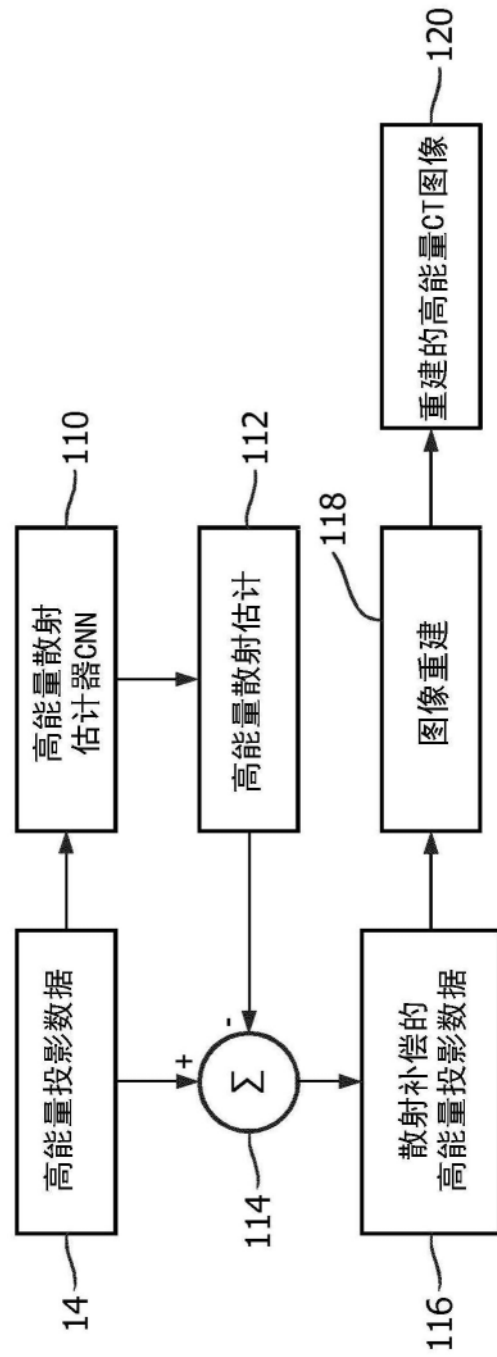


图4

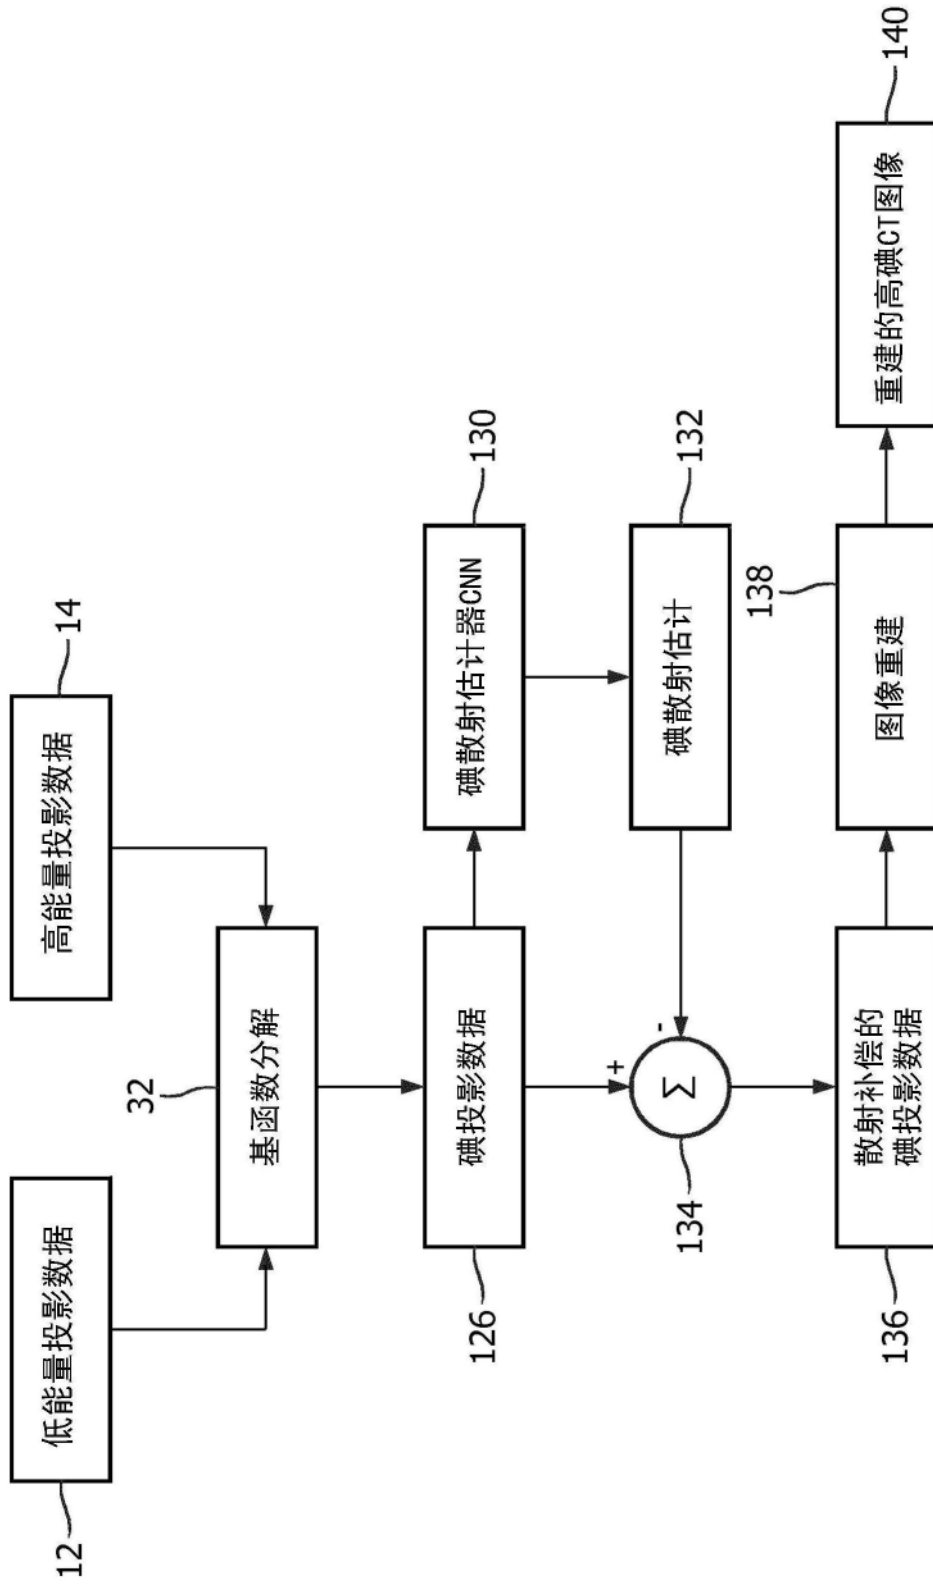


图5

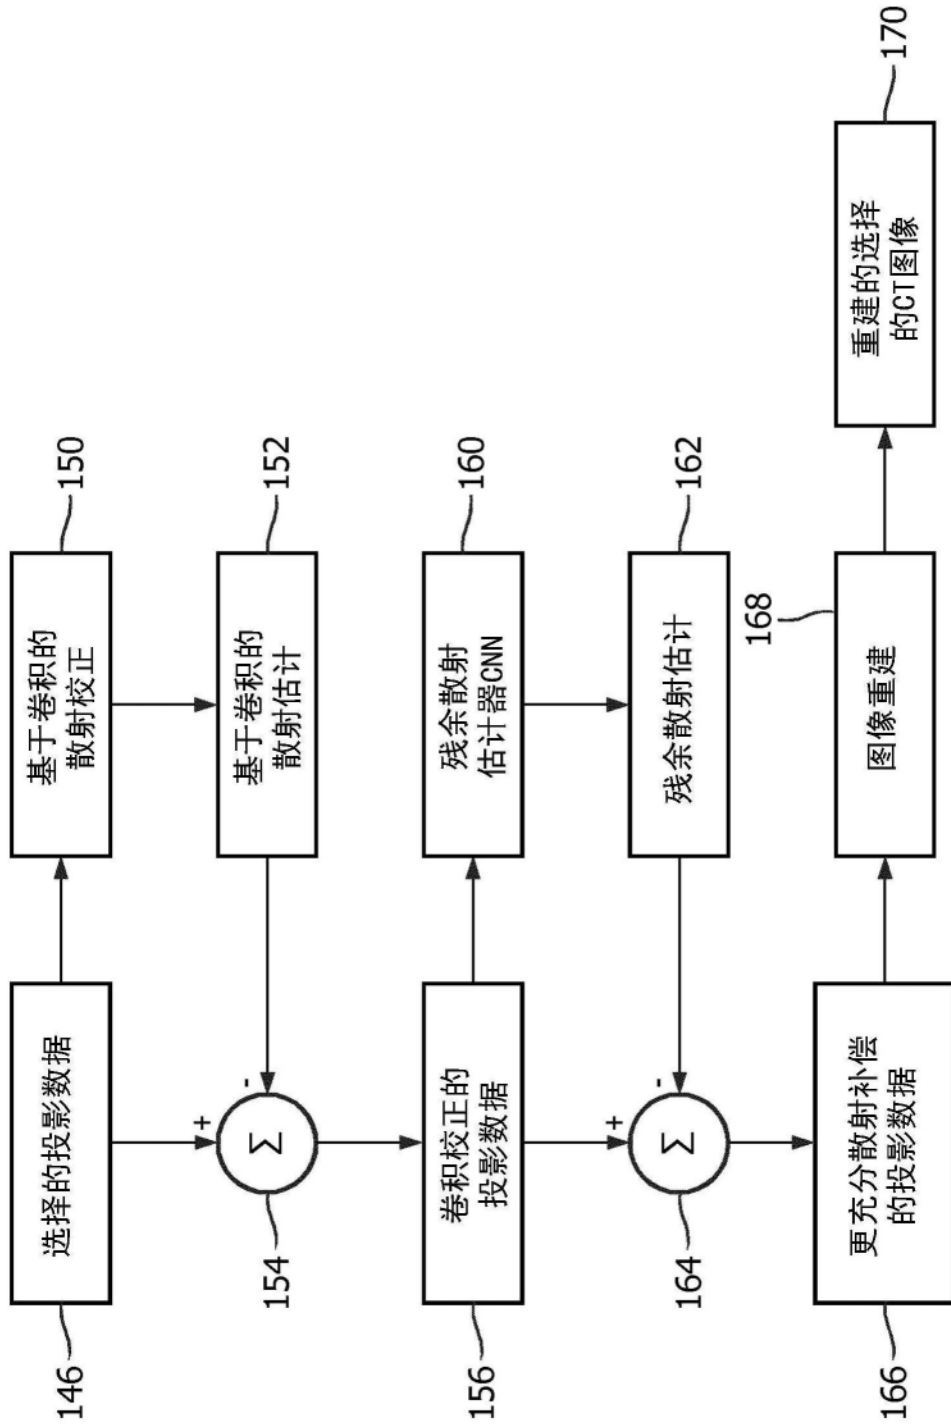


图6

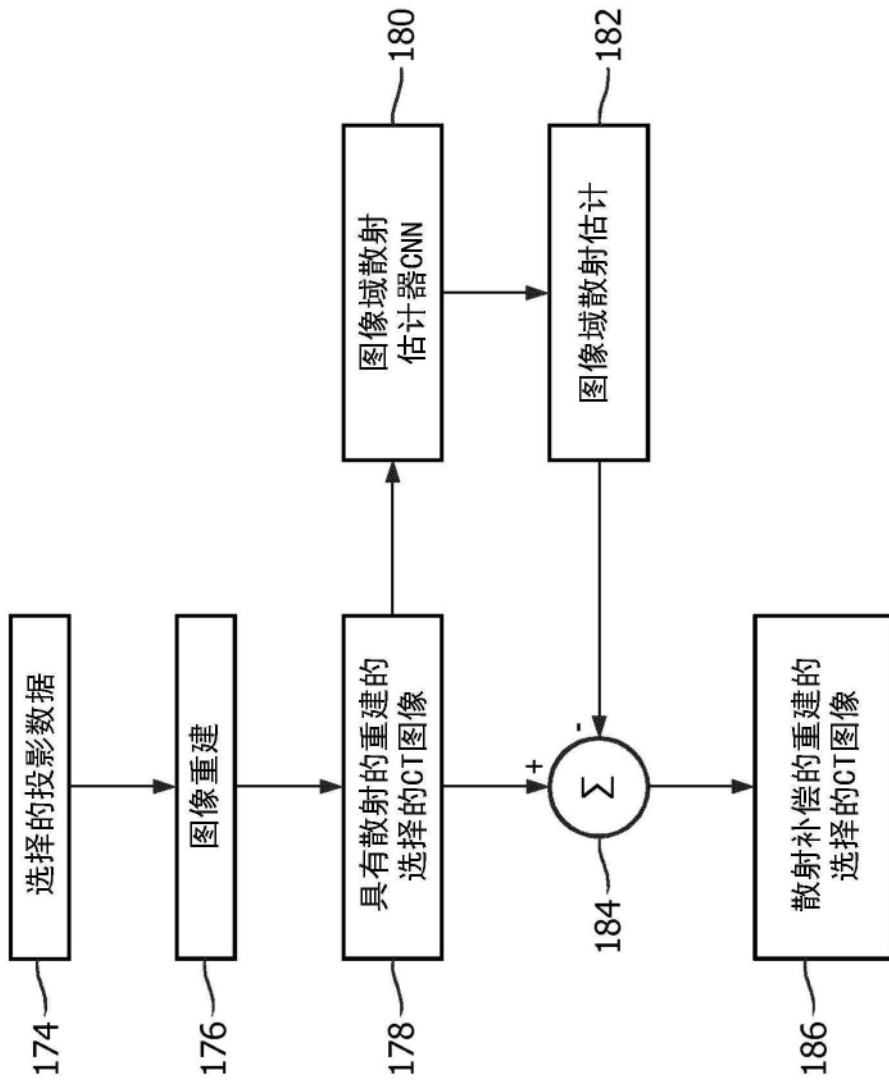


图7

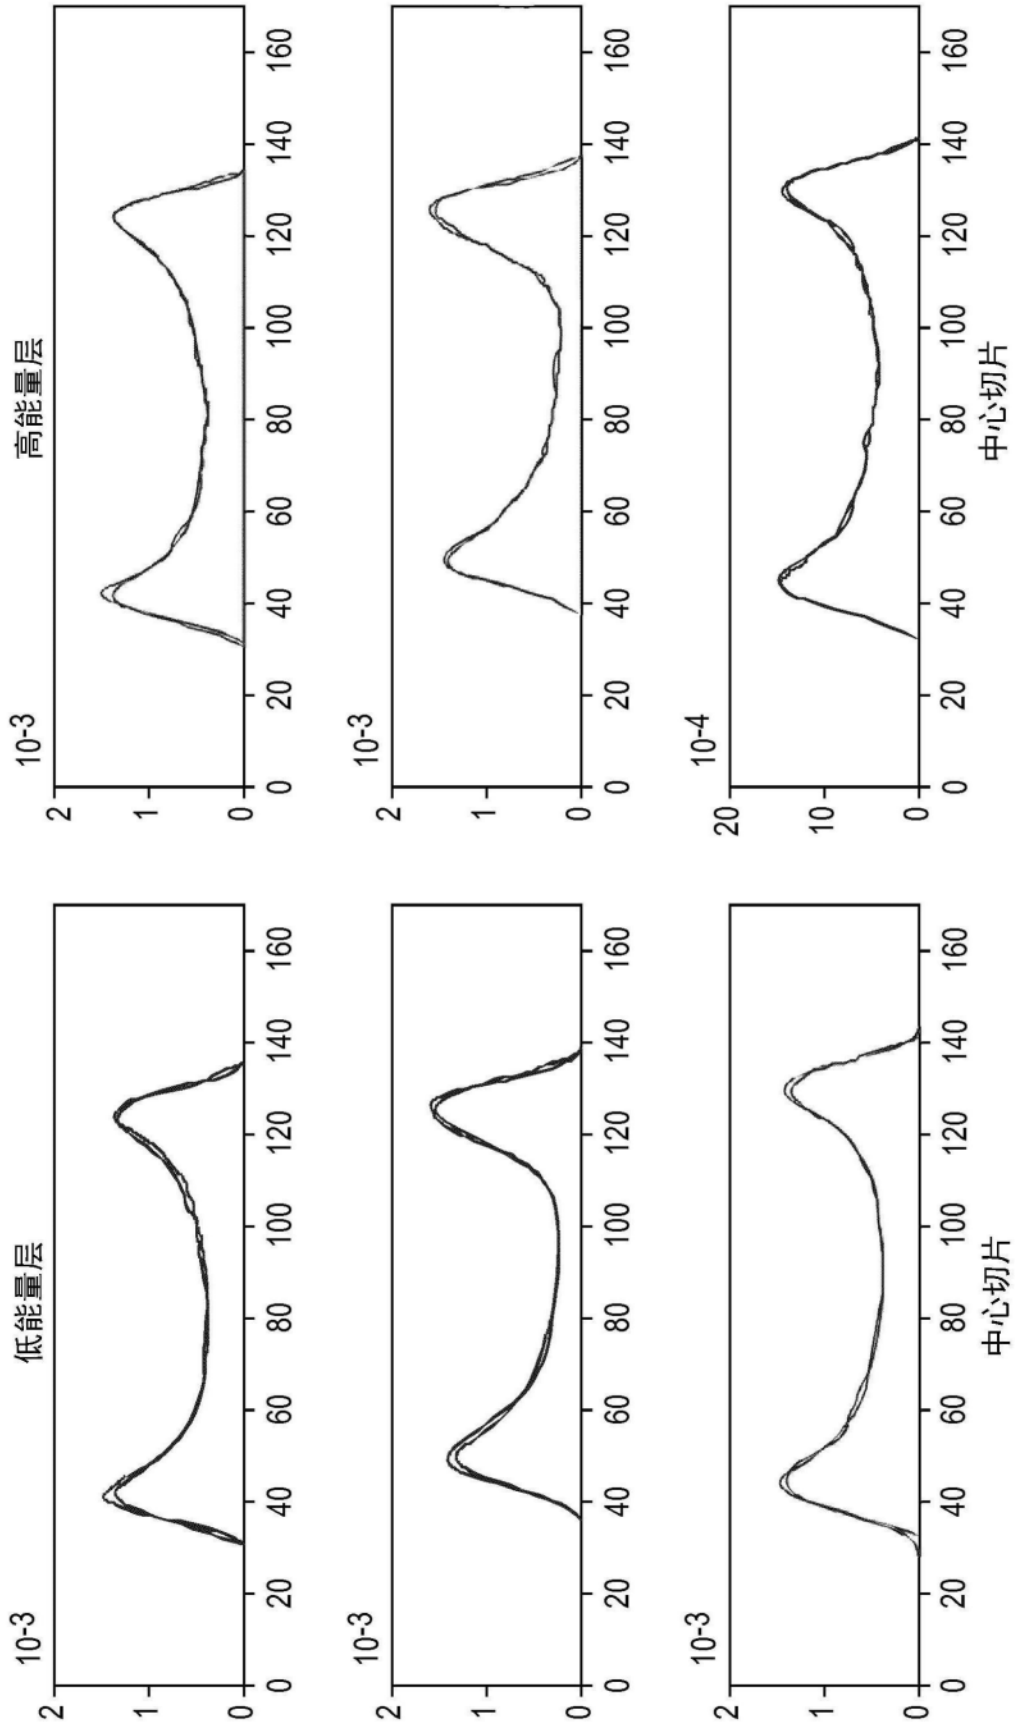


图8




图9




图10




图11