

基于卷积神经网络CT/CBCT影像质量自动分析

张俊¹, 朱金汉¹, 庄永东², 刘小伟², 陈立新¹

1. 华南肿瘤学国家重点实验室/中山大学肿瘤防治中心, 广东广州 510060; 2. 中山大学物理学院, 广东广州 510275

【摘要】目的:通过独立的程序自动分析数据,可以在减轻影像的质量保证(QA)工作量的同时,尽可能避免操作者主观因素造成的偏差。**方法:**对Catphan500/503/504/600的CT/CBCT影像按照功能模块进行分类,并通过卷积神经网络(CNN)进行学习,学习后对新输入的CT/CBCT影像可以自动识别并根据功能模块进行分类,继而对相关指标包括影像CT值的线性、调制传递函数以及均匀性等进行自动分析,以便确保临床应用的影像质量达到要求。**结果:**对于Catphan500扫描的CT图像和Catphan503扫描的CBCT图像,经过CNN自动分类对于功能模块CTP401、CTP404、CTP528都可以正确标记出来,但是CTP486的精确度没有达到100%,即有部分不属于CTP486的模块被错误判断成CTP486。同时均可实现对CT的HU线性、调制传递函数以及均匀性3个图像指标进行自动分析。**结论:**基于CNN能够准确地对CT/CBCT扫描的Catphan图像进行分类,下一步将拓展该方法到其他影像设备的QA体模,以便实现更广泛的自动影像质量保证。

【关键词】卷积神经网络;CT;锥形束CT;图像质量;自动分析

【中图分类号】R811.1

【文献标志码】A

【文章编号】1005-202X(2018)05-0557-08

Automatic analysis of CT/CBCT image quality based on convolutional neural network

ZHANG Jun¹, ZHU Jinhan¹, ZHUANG Yongdong², LIU Xiaowei², CHEN Lixin¹

1. Sun Yat-sen University Cancer Center/State Key Laboratory of Oncology in South China, Guangzhou 510060, China; 2. School of Physics, Sun Yat-sen University, Guangzhou 510275, China

Abstract: Objective To propose an independent program for automatic data analysis which can avoid errors caused by subjective factors of the operator while reducing the quality assurance workload. **Methods** The computed tomography/cone beam computed tomography (CT/CBCT) images of Catphan500/503/504/600 were classified according to functional modules and studied by convolutional neural networks (CNN). After training, the newly entered CT/CBCT images were automatically identified and sorted by functional modules, and then the related indicators were automatically analyzed, including HU linearity, modulation transfer function and uniformity of those images, aiming to ensure that the image quality met the requirements of clinical application. **Results** For the CT images of Catphan500 and the CBCT images of Catphan503, the function modules, including CTP401, CTP404 and CTP528, were correctly marked by CNN automatic classification. However, the accuracy of CTP486 didn't reach 100%, which indicated that some other modules were wrongly classified into CTP486. Meanwhile, the automatic analysis of HU linearity, modulation transfer function and homogeneity of CT was achieved. **Conclusion** Based on CNN, CT/CBCT images of Catphan can be classified accurately. The next step will be to extend the method to other imaging devices in order to achieve a wider range of automatic image quality assurance.

Keywords: convolutional neural network; computed tomography; cone beam computed tomography; image quality; automatic analysis

【收稿日期】2017-12-22

【基金项目】广东省自然科学基金(2014A030310188)

【作者简介】张俊, 技师, 研究方向: 放射治疗计划设计与计量学, E-mail: zhangjun@sysucc.org.cn

【通信作者】陈立新, 博士, 副研究员, 研究方向: 医学物理, E-mail: chenlx@sysucc.org.cn

前言

随着放射治疗技术的发展,特别是图像引导放疗技术(IGRT)的推广,对影像系统进行图像质量保证(QA)是放射治疗质量保证中重要的环节之一。其中,计算机断层(CT)影像是治疗计划实施的重要基础,在治疗计划设计阶段,依赖于CT对患者靶区及正常器官进行

勾画,并且基于CT图像进行剂量计算,而锥形束CT(CBCT)作为IGRT最常用的影像系统,是患者位置验证和校准的重要工具。不同的国际和国家组织,例如IEC、AAPM等都对CT图像质量的验收以及周期QA有相关的报告^[1],以便保证图像引导等精确放射治疗技术的实施^[2-5]。传统的影像分析方法需要人工画取分析区域或者选择对应的分析图像^[6-9]。主要是因为CBCT与CT存在一定的差异,例如体模散射的不同、有效视野(FOV)的差异,以及两种影像系统重建技术的差异,因此所生成图像CT-numbers、信噪比、调制传递函数(Modulation Transfer Function, MTF)等图像参数有较大差别^[10]。这就使得CT或者CBCT的影像QA分析软件不能完全自动识别两种影像系统生成的影像以及对应的影像QA模块^[11-13]。得益于最近深度学习的迅速发展,特别是卷积神经网络(Convolutional Neural Networks, CNN)在计算机视觉、图像识别以及特征提取中高准确度的表现^[14-15],开始应用于医疗影像中的辅助诊断以及图像分割^[16-20]。

本文将首次采用CNN对Catphan500/503/504/600(The Phantom laboratory, Salem NY, USA)的CT以及CBCT影像根据功能模块进行自动分类,从而实现两种影像系统通用的自动QA程序,从而有效减少

影像QA手工操作的工作量,并且可避免操作者主观选择不同的影像模块或者分析区域等造成的影响,确保影像质量分析的一致性。

1 材料与方法

1.1 训练数据采集和预处理

随机抽取4例Catphan500、6例Catphan503、3例Catphan504和1例Catphan600,共14组常规的CT或者CBCT的QA影像。CT影像是在一台Philips的CT Big Bore和一台Siemens的SOMATOM Definition AS扫描获得,扫描电压均是140 keV,扫描层厚3 mm,每张图像大小为512×512。CBCT影像分别在Elekta的Synergy医用直线加速器的XVI系统(Elekta AB, Stockholm, Sweden),以及Varian的Trilogy医用直线加速器的OBI系统(Varian Medical Systems, Palo Alto, CA)采集获得。重建体元边长为0.5 mm,图像大小为(384×384)~(520×520)。

选取不同Catphan类型的CT以及CBCT扫描的图像,从中提取CTP401、CTP404、CTP528、CTP486,以及Catphan功能模块外支撑部分图像,手工加上数字标记,输入进行训练。具体标记与对应模块示意图如图1所示。

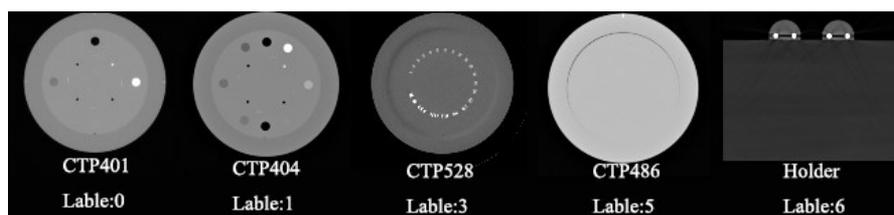


图1 Catphan不同功能模块及相应的数字标签

Fig.1 Different function modules of Catphan and their corresponding digital labels

所有输入的训练数据均进行以下处理:(1)为了统一训练时候的图像大小,方便训练数据的输入加快训练速度,所有图像统一插值成128×128;(2)另外采取一系列随机变换的方法来人为地增加训练数据:随机的上下左右翻转、随机变换图像的亮度、随机变换图像的对比度;(3)所有输入训练数据进行标准化处理,使得模型对图片灰度值的动态变化范围不敏感;(4)为避免训练时候连续相似或相同图像同一批次进行训练,造成过多神经元的输出总是零,需要对输入数据进行打乱随机(shuffle)输入。为了避免某个标签下的训练出现过拟合,各个模块的训练样本数目保持平衡。

1.2 CNN模型的建立

CNN是一种特殊的多层感知器架构,输入的图

像经过一系列神经元处理,可以从图像中提取并且识别出一致的特征,从而最终对新的图像做出预测。与基于机器学习的算法相比,CNN可以把图像中像素点的空间位置以及相邻像素点联合进行分析。这种联合邻近像素点的特性使得CNN在计算机视觉应用中,例如手写识别、人脸识别等有着出色的表现^[15,21]。

本研究构建的网络如图2所示,主要包含5层:2个卷积层(convolution layer)、2个基于修正线性激活的全连接层(fully connected layer)和1个线性转换的输出层。

第一个卷积层卷积核大小(5×5×1),输出64个神经元,卷积kernel平移步长为1。卷积层后面都会紧接线性激活函数(Rectified Linear Units, ReLU),最大

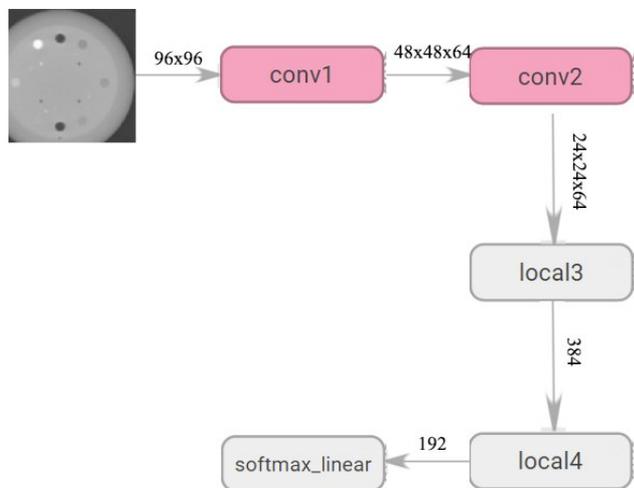


图2 CNN的总体结构图

Fig.2 General framework of convolutional neural network

Conv1 and conv2 are two convolution layers; local3 and local4 are two fully connection layers; softmax_linear is an output layer.

池化(max pool)以及局部的输入区域响应归一化。池化矩阵(3×3×1),位移步长(2×2×1)。区域响应归一化避免输出结果对图像的对比度和亮度变化敏感。输出结果输入到第二个卷积层中,第二个卷积层卷积核大小(5×5×64),输出64个神经元,同样经过ReLU、标准化、池化处理,然后输出给下一层网络。两组全链接层的作用是把经过卷积池化后的数据空间投影到定义的标签空间的隐藏神经层,主要通过ReLU激活函数来实现。最后通过softmax层的线性变换,根据拟合的权重以及偏置,输出对于输入图像不同标签下预测可能性强度结果。

神经网络的构建通过Google的tensorflow软件包实现。训练的batch为32,初始学习速率为0.1,学习速率衰减速度为0.1,执行batch次数为20 000,整个训练在英伟达GTX770M实现。

1.3 应用CNN实现Catphan的自动分类

经过训练后的网络可以对于新输入的图像给出不同标签下的预测强度,最简单的方法是选取强度最大的标签作为预测结果。但是为了避免因为图像质量或图像残缺等其他原因造成误判断,先对求出所有标签下的强度平均数 ϵ ,以及标准差 σ ,采用0.1的显著水平,即 $\epsilon+1.645\sigma$ 为强度上限,当且仅当只有一个标签的强度大于等于该上限时,才接受预测结果,否则认为该图像无法识别,并进行排除。本文中,未识别标记为255。如果有多张被识别同一类别的,则提取中间一层进行分析。

至此,可以对输入的整套CT或者CBCT的每层影像进行分类,能区分CTP401/404/486/528,然后结

合Catphan500/503/504/600的说明书,根据CTP401/CTP404(CTP401只存在于Catphan500,CTP404存在于Catphan503、Catphan504、Catphan600)与CTP528的位置关系,判断Catphan类型。判断条件如下(以头先进仰卧体位扫描,头方向为正方向,脚方向为负方向):

$$\begin{aligned} \text{Catphan500: } Z_{\text{CTP401}} - Z_{\text{CTP528}} &= 30 \text{ mm} \\ \text{Catphan503: } Z_{\text{CTP404}} - Z_{\text{CTP528}} &= 30 \text{ mm} \\ \text{Catphan504: } Z_{\text{CTP404}} - Z_{\text{CTP528}} &= -30 \text{ mm} \\ \text{Catphan600: } Z_{\text{CTP404}} - Z_{\text{CTP528}} &= 70 \text{ mm} \end{aligned} \quad (1)$$

1.4 CT/CBCT图像质量参数

本文选取分析图像质量参数有CT的值线性、MTF以及均匀性3个图像指标。当然实际图像质量指标不止这3项,基于本文重点是如何通过CNN实现自动图像QA,因此选取各模块比较有代表性的指标进行分析。

1.4.1 CT值线性 CTP401/404是一个包含4个或7个电子密度与材料不相同的模块。CTP401和CTP404包含材料以及对应电子密度如表1所示。当确定CTP401/404模块以及对体模定位后,可根据几何选取各个材料的中间区域的平均像素值作为该材料对应的CT值。

表1 CTP401与CTP404包含材料与对应电子密度
Tab.1 Materials contained in CTP401 and CTP404 and their relative electron density

Module	Material	Relative electron density
CTP401	Air	0.001
	Low density polyethylene	0.945
	Acrylic	1.147
	Teflon	1.868
CTP404	Air	0.001
	Polymethylpentene	0.853
	Low density polyethylene	0.945
	Polystyrene	0.998
	Acrylic	1.147
	Delrin	1.363
	Teflon	1.868

1.4.2 MTF MTF的测量通过CTP528分析获得,CTP528包含21组由铝条组成的线对,21组线对分别表示1~21 lp/cm。所有线对分布在以体模中心为圆心的圆上,因此可以通过提取圆上的profile分布,通

过式(2)计算线对的相对 MTF 值,相对 MTF 通过最小频率即间距最大的线对结果归一:

$$MTF(f) = \frac{CT_{peak} - CT_{valley}}{CT_{peak} + CT_{valley}} \quad (2)$$

其中,CT_{peak} 为线对中亮线的 CT 值,CT_{valley} 为暗线的 CT 值,当相对 MTF 小于 5%则不再进行分析。

1.4.3 均匀性 CT 值的均匀性通过均匀材料构成的 CTP486 测量获得。通过测量均匀模块的上中下左右 5 个区域的平均 CT 值,通过式(3)计算积分非均匀性,式(4)计算 Uniformity Index(UI)^[8]:

$$IntegralNon - Uniformity = \frac{CT_{max} - CT_{min}}{CT_{max} + CT_{min}} \quad (3)$$

$$UI = \frac{CT_{periphery} - CT_{center}}{CT_{center}} \quad (4)$$

其中,CT_{max}、CT_{min} 分别为 5 个区域中平均 HU 的最大值和最小值,CT_{center}、CT_{periphery} 分别中心区域以及边上区域的平均 CT 值,UI 取 4 个位置百分差异中绝对值最大的值。

1.5 图像质量 QA 的自动分析以及测试

根据第 1.3 节和第 1.4 节的内容,对新扫描的 CT/CBCT 图像进行自动图像质量 QA,步骤如下:(1)对 Catphan 体模进行扫描,至少保证扫描包含 CTP401/404 与 CTP528 两个模块;(2)利用已经训练好的 CNN,对扫描所有图像数据进行分类,并根据不同模块位置关系确定 Catphan 型号;(3)通过霍夫变换^[22]提取 Catphan 的外轮廓并计算圆心,对 Catphan 进行定位;(4)根据定位以及第 1.4 节内容,计算图像质量指标,得到分析结果。

选取 CT 与 CBCT 各 1 例新扫描的图像对该分析方法进行测试。CT 图像采用 Catphan500,在 Siemens 的 SOMATOM Definition AS 扫描,扫描电压 140 kV,管电流 280 mAs,FOV 266 mm,扫描层厚 3 mm。CBCT 的图像采用 Catphan503,在 Varian 的 Trilogy 医用直线加速器的 OBI 系统上扫描获取,扫描电压 100 kV,管电流 131 mAs,FOV 250 mm,重建层厚 2.5 mm。

对神经网络分类准确性进行分析,分析指标为:

$$精确度: Precision = TP / (TP + FP) \quad (5)$$

$$召回率: Recall = TP / (TP + FN) \quad (6)$$

其中,TP(True Positive)、FP(False Positive)、FN(False Negative)、TN(True Negative)定义为:模型预测与事实都是肯定的为 TP;模型预测与事实都是否定为 TN;模型预测为肯定,事实是否定为 FP;模型预测为否定,事实是肯定为 FN。

2 结果

2.1 CT 自动分析结果

对于 Catphan500 扫描的 CT 图像,经过 CNN 自动分类的统计结果见表 2,从表中可见主要功能模块 CTP401(标签 0)、CTP528(标签 3)都可以正确标记出来。但是 CTP486 的精确度没有达到 100%,即有部分不属于 CTP486 的模块被错误判断成 CTP486。图 3 是图像质量分析的结果。50%的 MTF 为 2.9 lp/cm,10%的 MTF 为 5.0 lp/cm。Uniformity Index 为 0.16%,Integral Nonuniformity 为 0.000 80。

表 2 Catphan500 的 CT 图像的自动分类结果统计(%)
Tab.2 Automatic classification results of CT images of Catphan500 (%)

Parameter	CTP401	CTP528	CTP486
Precision	100.0	100.0	51.7
Recall	100.0	100.0	100.0

2.2 CBCT 自动分析结果

图 4 是图像质量分析的结果。50%的 MTF 为 4.6 lp/cm,10%的 MTF 为 6.92 lp/cm。Uniformity Index 为 -1.23%,Integral Nonuniformity 为 0.006 18。Catphan503 扫描的 CBCT 图像,经过 CNN 自动分类的统计结果见表 3。跟 CT 结果相似,主要功能模块 CTP404(标签 1)、CTP528(标签 3)都可以正确标记出来,但 CTP486 也出现过多的错误判断。

3 讨论

本文研究结果显示,CNN 通过训练后,可用于 CT/CBCT 扫描的 Catphan 图像的不同模块的识别。通过 CNN 识别,可以通用有效地对影像系统 QA 图像自动识别,以实现自动 QA。早期传统影像系统的 QA 是通过人眼对 QA 体模扫描图像进行分析,因为窗宽窗位选择不同以及人主观判断的差异,会造成分析结果存在一些差异,而且对于如信噪比、均匀性 MTF 等指标无法给出一个定量的结果。虽然现在有一些能够定量分析图像质量的商业软件,如 CT AutoQA Lite(Iris QA, Frederick, MD, USA)、QALite(The Institute for Radiological Imaging Sciences, Inc, MD, US)、RIT(The Institute for Radiological Imaging Sciences, Inc, MD, US)等。但是一方面,因为 CT 以及 CBCT 图像质量的差异,一般不能通用分析^[9,11];另一方面,不同种类型号的影像 QA 体模存在差异,例如 Catphan 目前在市场有不同的型号,模体中对应的 QA 模块也有差异,如图 5 所示,CTP528 模块在

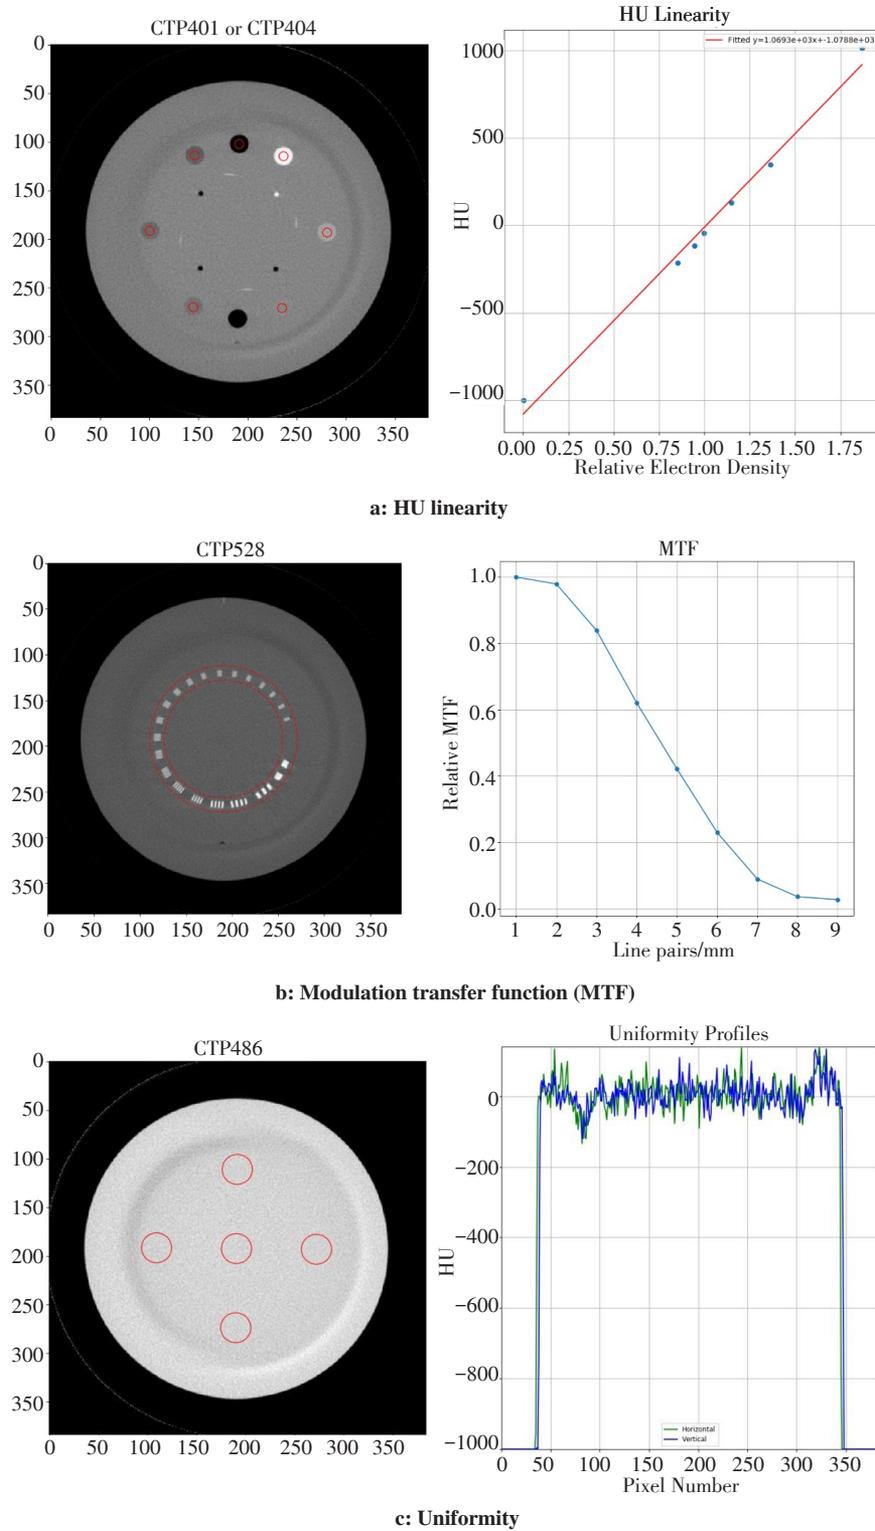


图3 Catphan500的CT影像图像质量分析

Fig.3 Image quality analysis of CT images of Catphan500

Red circles: Regions of interest for analysis

Catphan503、504以及600均有所差别。因此,一般的分析软件只能针对某型号体模自动分析^[12],或者通过用户采用手工分析方法,先选取对应Catphan型号,再选取对应的模块和分析区域。但不同操作者选择的层面可能不同,此外,当使用者对使用体模不

熟悉时,选择错误的模体或者错误的QA模块,会导致分析结果有较大偏差甚至错误。通过CNN可以有效提取图像特征,从而实现不同影像系统下模体和其中QA模块的自动识别,避免因为CT以及CBCT因为分辨率灰度值的差异造成识别的困难。同时通

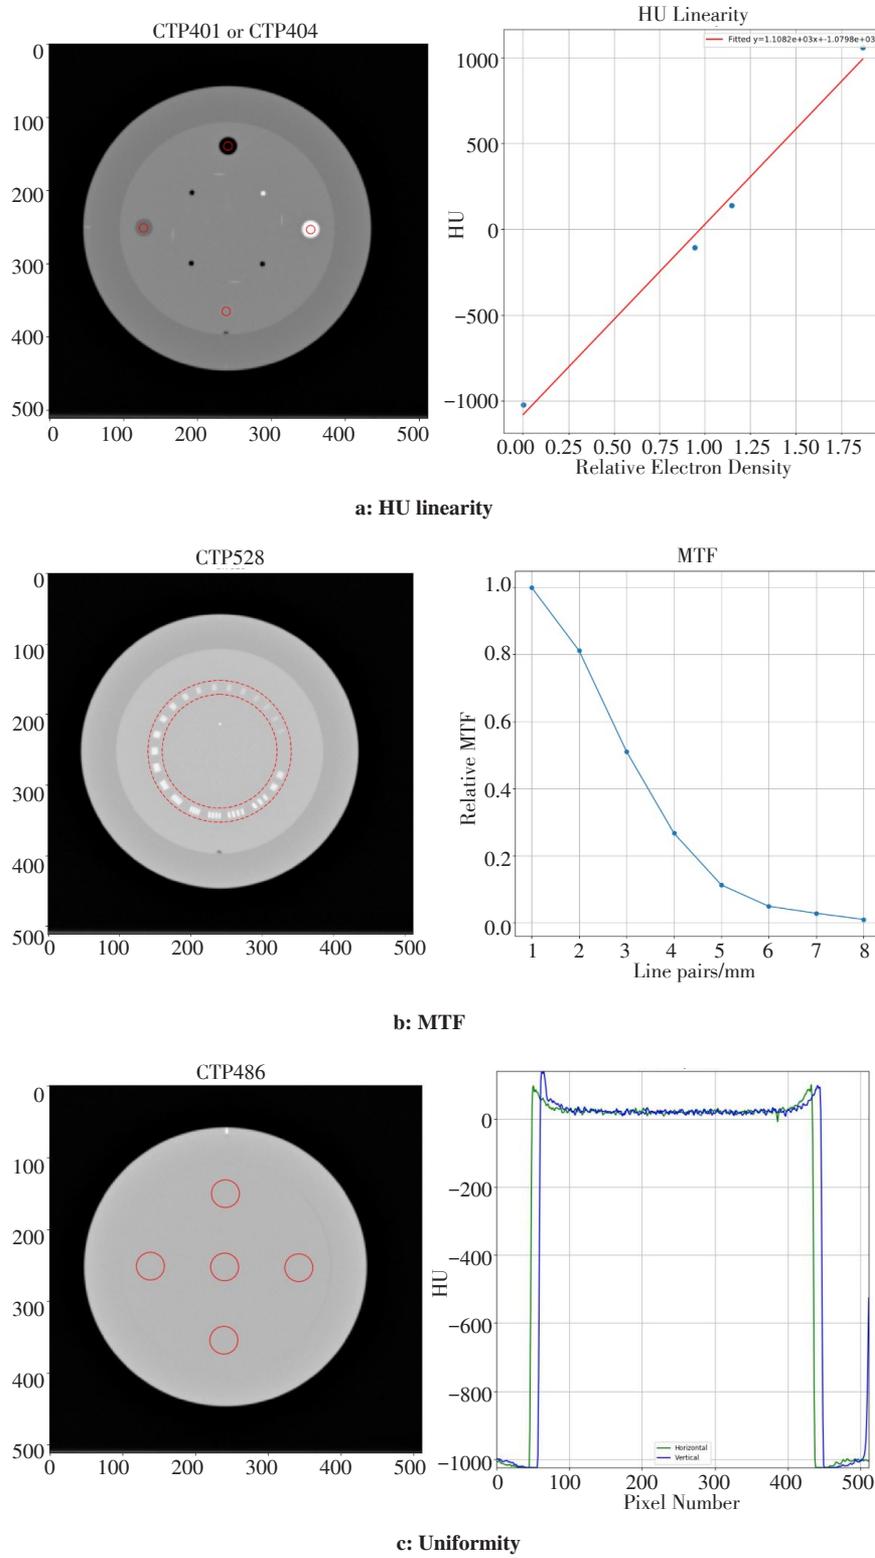


图4 Catphan503的CT影像图像质量分析

Fig.4 Image quality analysis of CT image of Catphan503

Red circles: Regions of interest for analysis

过机器学习自动识别模体以及对应的QA模块,可大大减少使用者初期的学习成本以及工作时间成本。

如果在训练数据以及训练标签中不加入 Holder (table: 6),当扫描图像包含 Catphan 的支撑臂部分

时,会出现CTP401、CTP404以及CTP528这3个标签可能性强度相近或其中一个较高的情形,从而会造成误判断。出现的原因有可能是支撑部分的图像包含如同CTP401、CTP404的多个圆排列结构,以及像

表3 Catphan503的CBCT图像的自动分类结果统计(%)

Tab.3 Automatic classification results of CBCT images of Catphan503 (%)

Parameter	CTP404	CTP528	CTP486
Precision	100.0	100.0	57.6
Recall	100.0	100.0	100.0

CTP528高亮的环状排列,从而对预测结果造成干扰(图6)。因此,本文在训练时输入支撑臂图像并加入标签,避免预测错误。

从表2和表3可以看出,有过多层面被识别为CTP486(lable:5),出现这种情况的原因是CTP486只是一个均匀的模块,扫描图像没有其他太多明显的

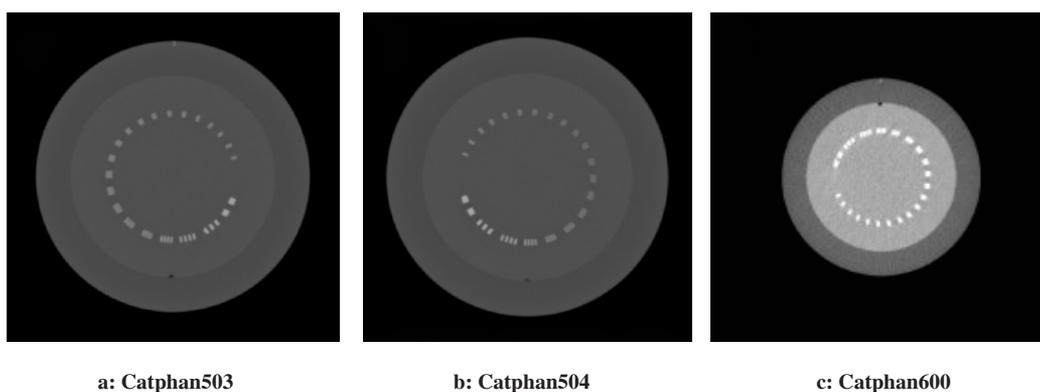


图5 CTP528模块
Fig.5 CTP528 modules

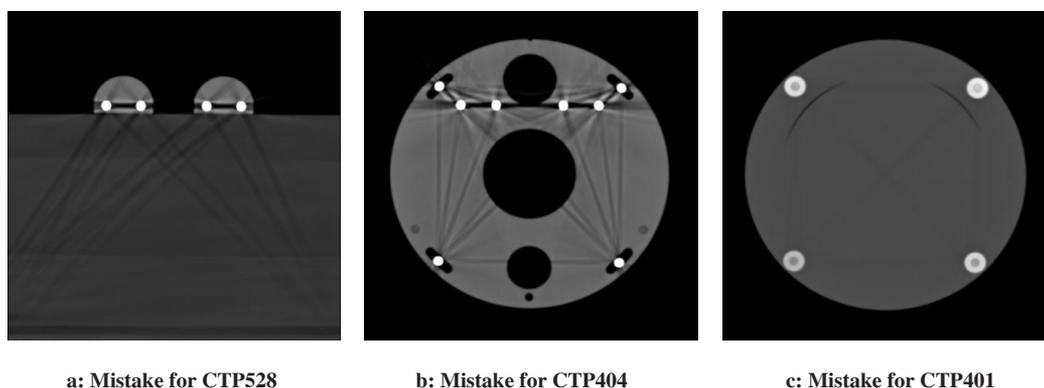


图6 Catphan支撑臂扫描图像
Fig.6 Scanned images of Catphan support arm

特征(图1)。而不同功能模块链接部分都是类似的均匀分布,因此会被误识别为CTP486。因此本文选取CTP401、CTP404以及CTP528对Catphan进行分类以及定位,然后再根据Catphan的几何关系确定CTP486的分析层面。

CNN模型具有较大可拓展性以及通用性,虽然本文只训练了Catphan体模,但是理论上只要在训练时加入其他图像QA体模的图像以及加上相应的标签,例如American College of Radiology (ACR) CT accreditation phantom、SEDENTEXCT phantom等^[11,13],甚至不是CT/CBCT图像,经过训练后均可以进行自动识别分类。例如,我们尝试选取用于Planar kV imaging 图像质量QA的Tor 18FG (Leeds Test

Objects, United Kingdom)作为lable:7加入训练。经训练后,可以在与Catphan混合在一起的图像中被识别出来。当图像被分类后,只需要根据图像具体说明参数,即可以方便实现图像质量不同指标自动分析。

4 结论

本文对CT/CBCT的Catphan图像通过CNN进行训练建立模型,结果显示,训练后的模型可以实现对Catphan图像自动分类,从而实现对CT/CBCT图像质量的自动化分析。进一步可以通过加入不同图像质量QA体模进行训练,从而实现具有更广泛适用性的自动图像QA程序,有效提高图像QA的效率。

【参考文献】

- [1] MUTIC S, PALTA J R, BUTKER E K, et al. Quality assurance for computed-tomography simulators and the computed-tomography-simulation process: report of the AAPM Radiation Therapy Committee Task Group No. 66[J]. *Med Phys*, 2003, 30(10): 2762-2792.
- [2] LÉTOURNEAU D, WONG J W, OLDHAM M, et al. Cone-beam-CT guided radiation therapy: technical implementation[J]. *Radiother Oncol*, 2005, 75(3): 279-286.
- [3] STEIDING C, KOLDITZ D, KALENDER W. Comparison of methods for acceptance and constancy testing in dental cone-beam computed tomography[J]. *Rofo*, 2015, 187(4): 283-290.
- [4] STANLEY D, PAPANIKOLAOU N, GUTIERREZ A. SU-E-J-24: an evaluation of the stability of image-quality parameters of Varian on-board imaging (OBI) and EPID imaging systems[J]. *Med Phys*, 2015, 41(2): 5088.
- [5] AYAN A S, LIN H, YEAGER C, et al. Should image rotation be addressed during routine cone-beam CT quality assurance?[J]. *Phys Med Biol*, 2013, 58(4): 1059.
- [6] DROEGE R T, MORIN R L. A practical method to measure the MTF of CT scanners[J]. *Med Phys*, 1982, 9(5): 758.
- [7] PAUWELS R, STAMATAKIS H, MANOUSARIDIS G, et al. Development and applicability of a quality control phantom for dental cone-beam CT[J]. *J Appl Clin Med Phys*, 2011, 12(4): 3478.
- [8] BISSONNETTE J, MOSELEY D J, JAFFRAY D A. A quality assurance program for image quality of cone-beam CT guidance in radiation therapy[J]. *Med Phys*, 2008, 35(5): 1807-1815.
- [9] GULLIKSRUD K, STOKKE C, MARTINSEN A C. How to measure CT image quality: variations in CT-numbers, uniformity and low contrast resolution for a CT quality assurance phantom[J]. *Med Phys*, 2014, 30(4): 521-526.
- [10] MAIL N, MOSELEY D J, JAFFRAY D. The influence of bowtie filtration on cone-beam CT image quality[J]. *Med Phys*, 2009, 36(1): 22-32.
- [11] HOBSON M A, SOISSON E T, DAVIS S D, et al. Using the ACR CT accreditation phantom for routine image quality assurance on both CT and CBCT imaging systems in a radiotherapy environment[J]. *J Appl Clin Med Phys*, 2014, 15(4): 5228.
- [12] STEIDING C, KOLDITZ D, KALENDER W A. A quality assurance framework for the fully automated and objective evaluation of image quality in cone-beam computed tomography[J]. *Med Phys*, 2014, 41(3): 031901.
- [13] DE OLIVEIRA M V, WENZEL A, CAMPOS P S, et al. Quality assurance phantoms for cone beam computed tomography: a systematic literature review[J]. *Dentomaxillofac Radiol*, 2017, 46(3): 20160329.
- [14] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. *Nature*, 2015, 521(7553): 436.
- [15] HOOCHANG S, ROTH H R, GAO M, et al. Deep convolutional neural networks for computer-aided detection: CNN architectures, dataset characteristics and transfer learning[J]. *IEEE Trans Med Imaging*, 2016, 35(5): 1285.
- [16] CHA K H, HADJIISKI L M, SAMALA R K, et al. Bladder cancer segmentation in CT for treatment response assessment: application of deep-learning convolution neural network-a pilot study [J] . *Tomography*, 2016, 2(4): 421-429.
- [17] GAO X W, HUI R, TIAN Z. Classification of CT brain images based on deep learning networks[J]. *Comput Methods Programs Biomed*, 2017, 138: 49-56.
- [18] HAVAEI M, DAVY A, WARDE-FARLEY D, et al. Brain tumor segmentation with deep neural networks[J]. *Med Image Anal*, 2017, 35: 18-31.
- [19] VORONTSOV E, TANG A, ROY D, et al. Metastatic liver tumour segmentation with a neural network-guided 3D deformable model[J]. *Med Biol Eng Comput*, 2017, 55(1): 1-13.
- [20] KOOI T, LITJENS G, GINNEKEN B V, et al. Large scale deep learning for computer aided detection of mammographic lesions[J]. *Med Image Anal*, 2016, 35: 303.
- [21] SHELHAMER E, LONG J, DARRELL T. Fully convolutional networks for semantic segmentation[J]. *IEEE Trans Pattern Anal Mach Intell*, 2017, 39(4): 640-651.
- [22] FERNANDES L A, OLIVEIRA M M. Real-time line detection through an improved Hough transform voting scheme[J]. *Pattern Recognition*, 2008, 41(1): 299-314.

(编辑:陈丽霞)