

DOI: 10.11830/ISSN.1000-5013.201911039



多任务深度卷积网络的 CT 图像方向校正

林家庆, 韩娟, 袁直敏, 彭佳林

(华侨大学 计算机科学与技术学院, 福建 厦门 361021)

摘要: 针对医学电子计算机断层扫描(CT)图像方向校正问题,提出一种并行卷积回归(PCRN)多任务深度学习网络.通过侧旋角度正回归和翻转概率逻辑回归,求得校正参数来精准地校正图像.进一步,针对医学图像训练样本稀缺的情况,提出一种串行回归(SCRN)的深度学习架构,弥补并行卷积回归网络在小样本情况下校正精度不足的问题.实验结果表明:在样本充分,并行卷积回归网络和样本稀缺情况下,串行卷积回归网络对小角度偏转、大角度偏转和翻转的腹部 CT 图像校正结果都优于传统的配准方法.

关键词: CT 图像; 方向校正; 深度卷积网络; 多任务回归网络

中图分类号: TP 183; R 814.42 **文献标志码:** A **文章编号:** 1000-5013(2020)03-0366-08

Orientation Correction for CT Images via Multitask Deep Convolutional Network

LIN Jiaqing, HAN Juan, YUAN Zhimin, PENG Jialin

(College of Computer Science and Technology, Huaqiao University, Xiamen 361021, China)

Abstract: To address the problem of orientation correction of CT image, a parallel convolution regression network (PCRN) with multitask deep learning is proposed. Orientation parameters are learned by the positive regression of the lateral rotation angle and the reversal probability logistic regression to accurate calibration images. Furthermore, in view of the lack in training samples for medical images, a deep learning frame named serial convolution regression network (SCRN) is introduced, which makes up for the inadequate correction accuracy of parallel convolutional regression network in the case of small samples. The experimental results show that the PCRN method with sufficient samples and the SCRN method with scarce samples are superior to the traditional registration methods in correcting CT images with small, large angles and flipped situation.

Keywords: CT image; orientation correction; deep convolution network; multitask regression network

医学图像理解的计算机辅助诊断/手术中,医学图像预处理是一个重要的步骤,是后续图像融合、目标检测和分割等任务的重要基础^[1].实现图像的方向校正最直接的方法是刚性配准,但配准方法通常只适用于方向偏差较小的情况,当偏差角较大时,配准结果准确性仍有不足^[2].Wei 等^[3]利用图像旋转后的插值阴影来进行旋转角度判别计算;Solanki 等^[4]通过打印出的图像的像素点特征来判断旋转角度.通过背景水平线检测来校正方向是一种常用的自然图像方向校正方案,但并不适合医学图像^[5].此外,一些研究者们将旋转角度控制在 90°的倍数来进行方向校正研究^[6],但没有解决连续值情况.基于深度

收稿日期: 2019-11-18

通信作者: 彭佳林(1985-),男,副教授,博士,主要从事机器学习及应用、图像处理和神经影像分析的研究. E-mail: 2004pjl@163.com.

基金项目: 国家自然科学基金资助项目(11771160)

学习方法的头部和手部等特定类别图像的方向校正^[7-12]的研究取得一定进展. Fischer 等^[13]尝试通过难度划分进行方向校正; de Vos 等^[14]尝试使用深度网络对图像进行局部的配准校正. 但这些研究只能对图像进行略微调整且主要针对自然图像, 而医学图像上方向校正的主要方法还是配准^[15].

深度学习方法虽然在数据充足的情况下可以表现出优异的性能, 但在数据稀缺时则表现一般. 因此, 如何构建在小样本训练集下的深度学习方向校正方法, 也是医学图像方向校正领域的一个主要挑战. 为解决上述方法的局限性, 本文提出一种基于深度卷积网络的图像旋转和翻转的校正方法, 以腹部 CT(computed tomography)图像数据集作为训练和验证集进行实验验证.

2 研究方法

2.1 大样本下并行卷积回归网络

在训练样本充足(大样本)的情况下, 建立并行卷积回归网络(parallel convolutional regression network, PCRN)来完成大样本下的方向校正任务, 着重考虑网络生成预测结果的效率. 即采用 PCRN 提取两个子任务的共享特征及专有特征, 然后通过最终层接上不同的回归器, 同时完成两项子任务的回归. 在面对侧旋角度回归和翻转状态回归两个回归任务时, 模型使用共同的浅层特征生成各自任务相关特征完成多项任务的回归. 网络结构如图 1 所示.




图 1 并行卷积回归网络结构图

Fig. 1 Network structure of parallel convolution regression network

该网络整体是一个特征编码残差网络, 分为数据输入、特征提取、参数输出三个部分. 具体地, PCRN 网络输入部分包含一个复制层, 将原始图像进行冗余复制, 以便后续的残差连接; 特征提取部分包含 4 个残差模块和 3 个下卷积层. 其中每两个残差模块间使用卷积核大小为 2×2 , 步长为 2×2 的下卷积层进行连接以压缩特征编码; 每个残差模块中使用的卷积核大小为 5×5 , 步长为 1×1 . 受 Highway 神经网络和残差网络的启发^[16-17], 残差模块中的浅层和深层特征间使用 Shortcut 连接, 使其中的卷积过滤器学到更容易习得的特征间残差^[16,18], 从而提高最终输出结果.

网络中的残差模块和下卷积层使用 ReLu 函数进行激活; 参数输出部分包含一个全连接层, 其输入为特征提取部分最后一层输出的高层语义特征, 输出为预测偏转角余弦值、预测偏转角正弦值, 以及图像翻转概率等 3 个目标方向校正参数. 选用侧旋角度的正弦值和余弦值作为预测输出的原因是, 使角度到输出的映射函数在 $(-180^\circ, 180^\circ]$ 范围均匀和连续^[19]. 上述全连接层侧旋校正输出使用 Tanh 激活函数, 翻转概率输出使用 Sigmoid 激活函数.

由于腹腔 CT 扫描图像为三维图像, 因此通过在横断面(垂直身体方向)均匀抽取的 N 个切片预测结果统计量来代表原图像的最终校正结果. 设网络输入为图像 I 的第 k 个切片 I^k , 输出为预测偏转角余弦值 z^k_{\cos} , 偏转角正弦值 z^k_{\sin} , 翻转概率 p^k . 图 2 为正余弦值符号与所在象限的关系. 综合 z^k_{\cos} 和 z^k_{\sin} 的符号可判断出偏转角所在的象限. 当偏转角所在象限确定后, 预测余弦值 α^k_{\cos} 和预测正弦值 α^k_{\sin} 计算式为




图 2 正余弦值符号与所在象限的关系

Fig. 2 Relationship between sine-cosine symbols and quadrants

$$(\alpha_{\cos}^k, \alpha_{\sin}^k) = \begin{cases} (\arccos(z_{\cos}^k), \arcsin(z_{\sin}^k)), & z_{\cos}^k \geq 0 \wedge z_{\sin}^k \geq 0, \\ (\arccos(z_{\cos}^k), -\arcsin(z_{\sin}^k) + \pi), & z_{\cos}^k < 0 \wedge z_{\sin}^k \geq 0, \\ (-\arccos(z_{\cos}^k), -\arcsin(z_{\sin}^k) - \pi), & z_{\cos}^k < 0 \wedge z_{\sin}^k < 0, \\ (-\arccos(z_{\cos}^k), \arcsin(z_{\sin}^k)), & z_{\cos}^k \geq 0 \wedge z_{\sin}^k < 0. \end{cases} \tag{1}$$

式(1)中:偏转角范围在 $(-\pi, \pi]$; $\alpha_{\cos}^k, \alpha_{\sin}^k$ 分别表示通过 z_{\cos}^k, z_{\sin}^k 计算出的偏转角.

通过式(1)可以由 z_{\cos}^k 和 z_{\sin}^k 计算出预测角度 α^k , 最终预测角度 α^k 通过 α_{\cos}^k 和 α_{\sin}^k 的均值来决定. 对 $\{\alpha^k, k=1, 2, \dots, N\}$ 取中值 α 作为预测的图像 I 的偏转角度, 对 $\{p^k, k=1, 2, \dots, N\}$ 取中值 p 作为预测的图像 I 的翻转概率. 若 p 大于翻转判定阈值 t , 则判定 I 翻转; 否则, 判定 I 未翻转.

因此, 最终从 z_{\cos}^k 和 z_{\sin}^k 映射到预测角度 α^k 的函数 g 的表达式为

$$\alpha^k = g(z_{\cos}^k, z_{\sin}^k) = \begin{cases} (\arccos(z_{\cos}^k) + \arcsin(z_{\sin}^k))/2, & z_{\cos}^k \geq 0 \wedge z_{\sin}^k \geq 0, \\ (\arccos(z_{\cos}^k) - \arcsin(z_{\sin}^k) + \pi)/2, & z_{\cos}^k < 0 \wedge z_{\sin}^k \geq 0, \\ (-\arccos(z_{\cos}^k) - \arcsin(z_{\sin}^k) - \pi)/2, & z_{\cos}^k < 0 \wedge z_{\sin}^k < 0, \\ (-\arccos(z_{\cos}^k) + \arcsin(z_{\sin}^k))/2, & z_{\cos}^k \geq 0 \wedge z_{\sin}^k < 0. \end{cases} \tag{2}$$

文中使用的偏差角回归损失函数为均方误差损失, 即为

$$L_{\text{ang}} = (\cos(gt) - z_{\cos})^2 + (\sin(gt) - z_{\sin})^2. \tag{3}$$

式(3)中: gt 为图像偏转角度真值; z_{\cos}, z_{\sin} 分别为网络输出预测偏转角的余弦值和正弦值.

翻转概率逻辑回归使用交叉熵损失, 即

$$L_{\text{rev}} = -(r \cdot \lg p + (1 - r) \cdot \lg(1 - p)). \tag{4}$$

式(4)中: r 为图像翻转真值, 翻转为 1, 否则为 0; p 是网络判断图像为翻转的概率输出.

总损失函数 L 为两个损失函数之和, 即

$$L = L_{\text{ang}} + L_{\text{rev}}. \tag{5}$$

在样本数量充足的情况下, PCRN 只需一次前向传播就能生成所有结果, 速度快且效率高; 但在样本数量较少的情况下, PCRN 的校正能力仍有限.

2.2 小样本下串行卷积回归网络

在训练样本稀缺(小样本)的情况下, 采用串行卷积回归网络(serial convolutional regression network, SCRN)先完成较为简单的侧旋角度回归任务; 然后, 通过预测的校正角度将图像基本转回正位, 继而对图像进行翻转判定, 如图 3 所示.




图 3 串行卷积回归网络结构图

Fig. 3 Network structure of serial convolutional regression network

首先构建侧旋校正网络预测三维图像侧旋角度 α ,然后通过 α 将图像基本调回正位,最后再使用翻转判定网络对基本处于正常位置的图像进行翻转判定.该方法中的两个网络与“并行卷积回归”中的网络基本相同,不同点在于:前面的侧旋校正网络少了翻转概率输出,后面的翻转判定网络少了侧旋角度正弦值和余弦值输出.

在侧旋校正阶段,按照PCRN方法可以预测三维图像 I 的偏转角 α .图4为坐标旋转变换示意图.对于经旋转 α 角度后的图像 I 上的每一点 (x', y') ,应用坐标旋转公式

$$[x, y] = [x', y'] \cdot \begin{bmatrix} \cos(\alpha) & -\sin(\alpha) \\ \sin(\alpha) & \cos(\alpha) \end{bmatrix}, \quad (6)$$

计算出其旋转前坐标 (x, y) .由于图像像素点坐标为整数,通过双线性插值方法可以求得旋转 α 前的图像 I .该阶段使用式(3)所述的损失函数.

在翻转判定阶段,训练时对未发生侧旋的输入切片进行 $[-5^\circ, 5^\circ]$ 范围内的随机侧旋,以模拟侧旋校正网络的输出偏差.测试时输入经过侧旋校正网络校正后的切片,通过输出翻转概率判定原图是否发生了翻转.该阶段使用式(4)所述的损失函数.




图4 坐标旋转变换示意图

Fig. 4 Demonstration of coordinate rotation transformation

3 实验结果与分析

3.1 实验设置

在实验中,训练和验证数据使用ISBI 2017肝脏肿瘤分割竞赛训练数据集集中的130个三维CT扫描图像.其中,100个为训练数据,30个为验证数据.测试数据集使用Codalab肝脏肿瘤分割竞赛测试数据集集中的70个CT扫描图像.对训练数据进行如下预处理:1)截取数据灰度范围到 $[-100, 250]$,以消除大量无用的灰度信息,再等比例缩放至 $[0, 1]$;2)在垂直方向上截取从盆骨上沿到胸腔下沿的图像区域;3)将每个三维图像数据在垂直方向上进行切片,并将分辨率从 $512 \text{ px} \times 512 \text{ px}$ 下采样到 $256 \text{ px} \times 256 \text{ px}$,以减小深度网络的体积和计算负荷;4)将切片数据在 $(-180^\circ, 180^\circ)$ 范围内进行随机旋转,以作为训练输入数据;5)对切片数据随机进行倍数范围在 $[0.95, 1.05]$ 的尺度缩放和灰度缩放.

为精确测量对比几种方向校正方法的能力,实验中对测试和验证数据进行了扩充.即除了对每个数据进行了上述灰度范围处理和区域截取外,还将每个区域截取后的三维数据切分为腹腔下部、腹腔中部和腹腔上部等3个区域.由此,总测试数据就达到 $70 \times 3 = 210$ 个,验证数据达到 $30 \times 3 = 90$ 个.对所有测试数据,实验先随机抽取50%进行翻转,再随机抽取50%变换为侧旋角度在 $(-180^\circ, -90^\circ]$ 和 $[90^\circ, 180^\circ]$ 范围内的“大角度”样本,剩下的随机变换为侧旋角度在 $(-90^\circ, 90^\circ)$ 范围内的“小角度”样本.对于验证数据也进行以上操作.另外,考虑到现实中医疗图像数据通常较为稀缺,从100个训练数据中抽取10个作为小样本训练数据集,在实验中对训练样本稀缺时的深度学习方向校正方法也进行了研究.

文中模型训练阶段,网络使用Adam优化方法进行网络参数优化.Adam动量参数按照文献[20]的推荐,设 $\beta_1 = 0.9$, $\beta_2 = 0.999$;初始学习率设为 $\lambda = 1.0 \times 10^{-4}$,在训练中逐步递减,最小到 $\lambda = 1.0 \times 10^{-5}$;批量大小为24,翻转判定阈值为0.9.除了按照节2所述使用切片校正结果中位数代表三维图像校正结果,实验中还使用切片校正结果均值代表三维图像校正结果以便对比分析.实验评价指标分为侧旋校正和翻转判定两个方面,前者使用平均误差角度作为评价指标,后者使用错判率作为评价指标.

3.2 用于对照的基线方法

以传统配准校正方法作为基线方法进行对照比较.实验选取的参考切片和待校正切片大体在人体同一位置,以确保配准效果良好.由于参考切片和待配准切片内部结构较为相似并且图像本身不存在形变,因此考虑使用仿射变换进行配准[2].配准的变换参数定为缩放倍数、平移向量和旋转角度等3个参数,并在配准完成一次后将图像进行翻转后再次进行配准,通过比较两次配准的最优结果来判断图像是否发生了翻转.配准度量方法为平均平方误差,配准过程中的优化方法为梯度下降法.

进一步的,考虑到待配准切片和参考切片在腹腔内部细节上存在不同,实验考虑屏蔽内部细节差异以进一步提高旋转校正配准精度,并设计了第二种配准方法.即先将参考图像和待校正图像切片进行躯

干内部填充,屏蔽掉躯体内部差异,使其成为简单的类椭圆二值图形;然后,按照第一种方法进行仿射变换配准.第二种方法由于屏蔽了腹腔内部细节差异而腹腔外形又为左右对称结构,翻转预测预期较差.最后,对于每个三维图像的方向校正结果,使用该图像中抽取切片的测试结果统计量,如平均值或中位数,作为三维图像方向校正最终值.

3.3 结果分析

在样本充足下,PCRN 和基线方法估算的平均方向偏差测试结果,如表 1 所示.

表 1 样本充足下 PCRN 和基线方法估算的平均方向偏差

Tab. 1 Average orientation error estimated by PCRN and baseline method on dataset with sufficient samples (°)

| 平均偏差 | PCRN | | 原始配准方法 | | 基于内部填充的配准方法 | |
|------|-------|-------|--------|--------|-------------|--------|
| | 均值 | 中位数 | 均值 | 中位数 | 均值 | 中位数 |
| 小角度 | 1.88 | 2.46 | 5.89 | 5.30 | 2.81 | 2.55 |
| 大角度 | 33.81 | 1.99 | 169.30 | 188.75 | 180.30 | 182.51 |
| 翻转 | — | 0.021 | — | 0.168 | — | 0.475 |

由表 1 可知:样本充足情况下,文中所提出的深度学习“并行卷积回归”方法对比参考方法在小角度情况下有略微的优势.进一步深入了解发现,参考方法的校正结果受配准时选择的参考切片影响较大.图 5 为配准方法的多最优解情况.从如图 5 可知:当选择的参考切片与待配准切片外形差别较大时,就可能出现多最优解的情况,从而导致校正效果不佳,而文中提出的方法能较好地解决该问题.





图 5 配准方法的多最优解情况

Fig. 5 Multiple optimal solutions of registration method

由表 1 还可知:文中所提出的深度学习“并行卷积回归”实验结果中,中位数统计结果与小角度情况下并无太大差异,而均值统计结果则明显较差.图 6 为校正角度符号相反的结果图.由图 6 可知:在极大角度情况下,校正角度在绝对值上差异不大,符号却可能相反,导致均值受巨大影响.

参考方法取得局部最优的典型示例,如图 7 所示.由图 7 可知:参考方法可能因优化方向错误导致最终结果陷入局部最优,所以在大角度情况下的校正结果明显差于文中所提的方法.


PCRN 典型方向校正结果,如图 8 所示.由图 8(a),(b),(d),(e)可知:在样本充足情况下,文中提出的深度学习“并行卷积回归”方法在侧旋校正和翻转判定两个子任务上都取得了优异的表现.这说明网络充分的提取了图像的侧旋校正特征和翻转判定特征.进一步,通过对错判的翻转样本分析得知,由



(a) 侧旋角度为 -177° 的切片 a (b) 将 a 校正 177° 后的图像 (c) 将 a 校正 -179° 后的图像

图 6 校正角度符号相反的结果示意图

Fig. 6 Results of the opposite correction angle sign



(a) 待配准切片 (b) 参考切片 (c) 待配准切片校正结果



(d) 内部填充后的待配准切片 (e) 内部填充后的参考切片 (f) 正确的校正结果

图 7 参考方法取得局部最优的典型示例

Fig. 7 Typical examples of local optimal solution by reference method

于图像内左右辨识特征太过稀少,样本本身辨识度太低,导致切片翻转判断错误(如图 8(e),(f)所示). 在实际应用中,通过统计同一个三维图像的整体翻转标识来避开该问题. 参考方法中的原始配准方法由于配准误差大,导致翻转的最终判定受到较大影响,准确率较低;而内部填充的配准方法则基本没有翻转辨识的能力.



(a) 小角度下典型切片 a (b) 大角度下典型样本切片 b (c) 左右相似的难分样本 c



图 8 PCRN 典型方向校正结果展示

Fig. 8 Typical orientation correction results by PCRN

在样本稀缺下,SCRN 和 PCRN 估算的平均方向偏差测试结果,如表 2 所示.由表 2 可知:在样本稀缺情况下,使用 SCRN 方法侧旋校正效果接近表 1 中样本充足下的侧旋校正效果,且比样本稀缺下的 PCRN 方向校正效果好.此时,PCRN 在小角度侧旋校正方面已经不如内部填充的配准方法.在翻转校正上,由于样本数量太过稀少的原因,PCRN 翻转识别能力相比于样本充足情况下下降较多.但可以看到 SCRN 方法此时在翻转偏差平均值上,还是明显优于 PCRN 方法的.

表 2 样本稀缺下 SCRN 和 PCRN 估算的平均方向偏差

Tab. 2 Average orientation error estimated by SCRN and PCRN on dataset with limited samples (°)

| 平均偏差 | SCRN | | PCRN | |
|------|-------|-------|-------|-------|
| | 均值 | 中位数 | 均值 | 中位数 |
| 小角度 | 2.27 | 2.66 | 4.89 | 5.37 |
| 大角度 | 35.52 | 2.81 | 37.39 | 5.21 |
| 翻转 | — | 0.043 | — | 0.120 |

4 结论

将复杂的 CT 图像方向校正任务分解为简单的侧旋角度校正回归和翻转概率逻辑回归两个回归子任务,并针对不同样本数量的数据集,分别以并行和串行的方式设计了两种多任务深度学习网络——PCRN 和 SCRN.

经典的仿射配准方法需要在同时估计缩放、平移参数和旋转参数情况下,才能实现较为准确的旋转和翻转估计.而文中提出的神经网络方法一个最大优势是,可以在无需估计缩放和平移的前提下,实现对旋转和翻转的更精准估计.在公开数据集上的实验结果证明文中提出的方法,在小角度侧旋、大角度侧旋和翻转判断上都有着较强的校正能力,具有很强的应用价值.后续研究将把串行回归的两个网络连接到一起,实现直接的端到端输出,以简化训练过程,提高模型精度.

参考文献:

[1] TRIVEDI D N, SHAH N D, KOTHARI A M, *et al.* DICOM[®] medical image standard[M]//Dental Image Processing for Human Identification. Berlin: Springer, Cham, 2019: 41-49. DOI: 10.1007/978-3-319-99471-0_4.

[2] SONG Guoli, HAN Jianda, ZHAO Yiwen, *et al.* A review on medical image registration as an optimization problem [J]. Current Medical Imaging Reviews, 2017, 13(3): 274-283. DOI: 10.2174/1573405612666160920123955.

[3] WEI Weimin Wei, WANG Shuozhong, ZHANG Xinpeng, *et al.* Estimation of image rotation angle using interpolation-related spectral signatures with application to blind detection of image forgery[J]. IEEE Transactions on Information Forensics and Security, 2010, 5(3): 507-517. DOI: 10.1109/tifs.2010.2051254.

[4] SOLANKI K, MADHOW U, MANJUNATH B S, *et al.* Estimating and undoing rotation for print-scan resilient data hiding[C]//International Conference on Image Processing. Singapore: IEEE Press, 2004: 39-42. DOI: 10.1109/ICIP.2004.1418684.

[5] FEFILATYEV S, SMARODZINAVA V, HALL L O, *et al.* Horizon detection using machine learning techniques [C]//International Conference on Machine Learning and Applications. Orlando: IEEE Press, 2006: 17-21. DOI: 10.1109/ICMLA.2006.25.

[6] VAILAYA A, ZHANG Hongjiang, YANG Changjiang, *et al.* Automatic image orientation detection[J]. IEEE Transactions on Image Processing, 2002, 11(7): 746-755. DOI: 10.1109/tip.2002.801590.

- [7] ESTEVA A, ROBICQUET A, RAMSUNDAR B, *et al.* A guide to deep learning in healthcare[J]. *Nature Medicine*, 2019, 25(1): 24-29. DOI: 10.1038/s41591-018-0316-z.
- [8] PRINCE M, ALSUHBANY S A, SIDDIQI N A. A step towards the optimal estimation of image orientation[J]. *IEEE Access*, 2019, 7: 185750-185759.
- [9] OSADCHY M, CUN Y L, MILLER M L. Synergistic face detection and pose estimation with energy-based models[J]. *Journal of Machine Learning Research*, 2007, 8: 1197-1215.
- [10] BALTRUSCHAT I M, SAALBACH A, HEINRICH M P, *et al.* Orientation regression in hand radiographs: A transfer learning approach[C]// *Medical Imaging 2018: Image Processing*. Houston: SPIE, 2018. DOI: 10.1117/12.2291620.
- [11] SAFONOV I V, KURILIN I V, RYCHAGOV M N, *et al.* Content-based image orientation recognition[M]// *Adaptive Image Processing Algorithms for Printing*. Singapore: Springer, 2018: 269-277. DOI: 10.1007/978-981-10-6931-4_12.
- [12] MORRA L, FAMOURI S, KARAKUS H C, *et al.* Automatic detection of canonical image orientation by convolutional neural networks[C]// *IEEE 23rd International Symposium on Consumer Technologies (ISCT)*. Ancona: IEEE Press, 2019: 118-123.
- [13] FISCHER P, DOSOVITSKIY A, BROX T. Image orientation estimation with convolutional networks[C]// *German Conference on Pattern Recognition*. Switzerland: Springer, 2015: 368-378. DOI: 10.1007/978-3-319-24947-6_30.
- [14] de VOS B D, BERENDSEN F F, VIERGEVER M A, *et al.* A deep learning framework for unsupervised affine and deformable image registration[J]. *Medical Image Analysis*, 2019, 52: 128-143. DOI: 10.1016/j.media.2018.11.010.
- [15] EPPENHOF K A J, LAFARGE M W, VETA M, *et al.* Progressively trained convolutional neural networks for deformable image registration[EB/OL]. [2019-11-15]. <https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=8902170>. DOI: 10.1109/TMI.2019.2953788.
- [16] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, *et al.* Deep residual learning for image recognition[C]// *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Las Vegas: IEEE Press, 2016: 770-778. DOI: 10.1109/CVPR.2016.90.
- [17] ZILLY J G, SRIVASTAVA R K, KOUTNÍK J, *et al.* Recurrent highway networks[C]// *Proceedings of the 34th International Conference on Machine Learning*. Sydney: IEEE Press, 2017: 4189-4198.
- [18] HUANG Gao, LIU Zhuang, PLEISS G, *et al.* Convolutional networks with dense connectivity[EB/OL]. [2019-05-23]. <https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=8721151>. DOI: 10.1109/TPAMI.2019.2918284.
- [19] LIN C H, LUCEY S. Inverse compositional spatial transformer networks[C]// *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Honolulu: IEEE Press, 2017: 2568-2576. DOI: 10.1109/CVPR.2017.242.
- [20] KINGMA D P, BA J. Adam: A method for stochastic optimization[EB/OL]. (2014-12-22)[2017-01-30]. <https://arxiv.org/abs/1412.6980>.

(责任编辑: 黄仲一 英文审校: 吴逢铁)