

胡万亭. 基于残差神经网络的大脑磁共振图像配准[J]. 智能计算机与应用, 2024, 14(11): 99-102. DOI: 10.20169/j.issn.2095-2163.241114

# 基于残差神经网络的大脑磁共振图像配准

胡万亭<sup>1,2</sup>

(1 濮阳职业技术学院, 河南 濮阳 457000; 2 河南大学 濮阳工学院, 河南 濮阳 457000)

**摘要:** 医学影像技术在现代医疗中的作用越来越大,但是不同时间或不同模态下的图像移动不可避免。医学图像配准对于病情诊断和治疗具有重要价值,但是传统配准算法迭代优化时间较长,还容易陷入局部最优。针对大脑核磁共振图像中的运动伪影,本文采用基于残差神经网络的刚性变换配准模型,预测刚性变换参数。模型采用无监督的方法,不需要变换参数作为标签,通过相似性度量作为损失函数约束模型的训练。实验结果表明,对于大脑核磁共振图像配准,模型具有非常好的配准效果,并且配准速度比传统方法有数十倍的提升,对于临床大脑核磁共振图像分析具有重要意义。

**关键词:** 核磁扫描图像; 残差网络; 无监督; 配准

中图分类号: TP301.6

文献标志码: A

文章编号: 2095-2163(2024)11-0099-04

## Registration of brain magnetic resonance images based on residual neural network

HU Wanting<sup>1,2</sup>

(1 Puyang Vocational and Technical College, Puyang 457000, Henan, China;

2 Puyang Institute of Technology, Henan University, Puyang 457000, Henan, China)

**Abstract:** Medical imaging technology plays an increasingly important role in modern medicine, but image movement in different time or different modes is unavoidable. Medical image registration is of great value for disease diagnosis and treatment, but the traditional registration algorithm takes a long time to optimize parameters, and it is easy to fall into local optimization. A registration model based on residual neural network is used to predict rigid transformation parameters of the brain MRI images. The unsupervised method is used in the proposed model, because it didn't require transformation parameters as labels. However, it needs similarity measurement as loss function to train the model. The experimental results show that the model has a very good registration effect for brain MRI Image, and the registration speed is dozens of times higher than that of traditional methods, which is of great significance for clinical brain MRI image analysis.

**Key words:** magnetic resonance imaging; residual network; unsupervised; registration

## 0 引言

图像配准是把不同时间或不同模态图像变换到同一坐标系下达到空间对齐的过程,被广泛应用到医学影像、遥感图像、机器视觉等各个领域。医学图像配准对于病情诊断、手术导航、疗效评估等方面具有重要的作用。从空间变换模型的角度,医学图像配准分为刚性变换、仿射变换、投影变换以及非线性变换等几类。从配准方法的角度,Zitová等学者<sup>[1]</sup>将图像配准大体地分成基于特征的方法和基于区域的方法。

近年来,基于深度学习的图像配准技术快速发

展,克服了传统配准方法速度慢的缺点,在配准速度上要远远超过传统配准算法。基于深度学习的配准算法大多采用卷积神经网络作为特征提取器,卷积或者全连接网络作为回归器<sup>[2-4]</sup>。配准算法按照是否需要训练标签,可分为有监督的配准和无监督的配准。其中,有监督的学习需要真实的变换参数或者变换空间作为标签,用来监督网络训练的过程<sup>[5-6]</sup>。Chee等学者<sup>[4]</sup>利用AIRNet网络实现了有监督的仿射图像配准。其中,网络由编码器和回归器两部分组成。其中,编码器基于DenseNet来提取特征,回归器由多个全连接层组来生成变换参数。Sokooti等学者<sup>[7]</sup>提出了一种有监督的可变形图像

**基金项目:** 濮阳职业技术学院校级自然科学科研项目(2023PZYKY41)。

**作者简介:** 胡万亭(1988—),男,讲师,主要研究方向:机器学习,图像处理。Email:huwanting@aliyun.com。

收稿日期: 2023-06-23

配准的网络结构 RegNet, 利用合成的光滑位移矢量场(DVF)去训练网络。Balakrishnan 等学者<sup>[8]</sup>提出了 VoxelMorph 是一种无监督的可变形图像配准网络, 使用 UNet 的编码器-解码器网络结构, 用来生成 DVF, 损失函数使用形变图像和参考图像之间的相似性度量, 不需要训练标签。

大脑核磁共振图像扫描过程较长, 病人头部运动难以完全避免, 但是不同于形变复杂的内脏器官, 头部基本上是刚性运动。针对大脑核磁图像, 本文设计了基于残差卷积神经网络的刚性配准算法。另外, 有监督的方法依赖于标签, 既增加了工作量, 又受到标签准确度的限制, 所以本文采用无监督的方案, 用变换后的图像和固定图像之间的相似度作为损失函数。网络模型以 BraTS 脑肿瘤核磁共振图像(MRI)为输入, 经过训练后可以准确实现各模态图像的配准, 配准速度也提高了数十倍。

## 1 相关技术

### 1.1 仿射变换与刚性变换

仿射变换包括图像的旋转、缩放、错切、平移等变化, 简单来说就是线性变换和平移, 2D 图像仿射变换公式如下所示:

$$\begin{pmatrix} \hat{x}_1 \\ \hat{y}_1 \\ \hat{z}_1 \end{pmatrix} = \begin{pmatrix} \hat{a}_{11} & \hat{a}_{12} & \hat{t}_x \\ \hat{a}_{21} & \hat{a}_{22} & \hat{t}_y \\ \hat{e}_0 & 0 & 0 \end{pmatrix} \begin{pmatrix} \hat{x}_0 \\ \hat{y}_0 \\ \hat{z}_0 \end{pmatrix} = \begin{pmatrix} \hat{a}_{11} \cdot x_0 + \hat{a}_{12} \cdot y_0 + \hat{t}_x \\ \hat{a}_{21} \cdot x_0 + \hat{a}_{22} \cdot y_0 + \hat{t}_y \\ \hat{e}_0 \end{pmatrix} \quad (1)$$

其中,  $x_0, y_0$  表示变换前像素坐标;  $x_1, y_1$  表示变换后像素坐标;  $\hat{a}_{11}, \hat{a}_{12}, \hat{a}_{21}, \hat{a}_{22}$  表示线性变换参数;  $\hat{t}_x, \hat{t}_y$  分别表示  $x$  和  $y$  方向上的平移量。二维矩阵仿射变换共有 6 个自由度。

刚性变换只包括了旋转和平移操作, 2D 图像刚性变换的数学公式具体为:

$$\begin{pmatrix} \hat{x}_1 \\ \hat{y}_1 \\ \hat{z}_1 \end{pmatrix} = \begin{pmatrix} \hat{e} \cos \theta & \hat{e} \sin \theta & \hat{t}_x \\ \hat{e} - \sin \theta & \hat{e} \cos \theta & \hat{t}_y \\ \hat{e}_0 & 0 & 0 \end{pmatrix} \begin{pmatrix} \hat{x}_0 \\ \hat{y}_0 \\ \hat{z}_0 \end{pmatrix} = \begin{pmatrix} \hat{e} \cos \theta \cdot x_0 + \hat{e} \sin \theta \cdot y_0 + \hat{t}_x \\ \hat{e} - \sin \theta \cdot x_0 + \hat{e} \cos \theta \cdot y_0 + \hat{t}_y \\ \hat{e}_0 \end{pmatrix} \quad (2)$$

其中,  $\theta$  表示变换前像素坐标向量与变换后像素坐标之间的夹角;  $\hat{t}_x, \hat{t}_y$  分别表示  $x$  和  $y$  方向上的平移量, 共有 3 个自由度。

本文的测试实验中, 3 个自由度的刚性配准精度一般好于 6 个自由度的仿射配准, 当然这与实验

的训练集和测试集有很大的关系。

### 1.2 残差网络

神经网络层数越多, 效果不一定越好, 甚至会出现严重的过拟合问题。针对这一问题, He 等学者<sup>[9]</sup>提出了残差神经网络(ResNet)。ResNet 的基本结构由残差块组成, 参见图 1。图 1 中,  $x$  表示输入,  $F$  表示残差函数,  $relu$  表示激活函数,  $\sigma(F(x) + x)$  表示输出, 残差块中的恒等函数部分也被称作跳跃连接, 这是 ResNet 避免过拟合的关键所在。




图 1 残差块

Fig. 1 Residual block

ResNet 的核心部分就是将同类若干的残差块连接起来, 经典的 ResNet 命名如 ResNet-18、ResNet-34、ResNet-50、ResNet-101 等, 这里的数字表示了全部的网络层数。实验表明, 34 层的普通卷积网络比 18 层的普通卷积网络效果要差, 出现了退化现象, 但是 ResNet-34 比 ResNet-18 效果要好, 而且同样层数的 ResNet 比普通卷积网络收敛速度要快, 证明了恒等映射可以快速传递信息, 还能有效避免梯度消失等问题。综上分析可知, ResNet 在避免深度网络过拟合问题的同时, 也加快了训练速度。

## 2 神经网络配准模型

### 2.1 网络架构

网络整体架构如图 2 所示。网络针对仿射变换和刚性变换进行设计, 线性变换参数通过特征提取器和回归器生成, 模型选用 ResNet 作为特征提取器, 全连接层作为回归器。图 2 中并未将全部卷积层和全连接层画出, 其中 ResNet 共 34 层, 回归部分共 2 层。按照网络输出的变换参数通过对移动图像进行重采样, 生成变换后的图像。损失函数通过固定图像和变换后图像的相似性度量来定义, 2.2 节将对此展开详述。

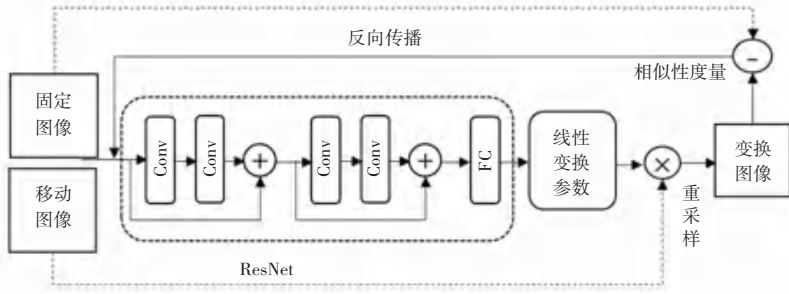


图 2 配准网络架构示意图

Fig. 2 Schematic diagram of the registration network

训练仿射变换配准模型时,变换参数是 6 个,即式(1)中的  $a_{11}$ 、 $a_{12}$ 、 $a_{21}$ 、 $a_{22}$ 、 $t_x$ 、 $t_y$ 。训练刚性变换配准模型时,变换参数是 3 个,即式(2)中的  $\theta$ 、 $t_x$ 、 $t_y$ 。核磁扫描过程中,大脑主要是刚性运动,分 2 次实验,旨在验证 6 个自由度和 3 个自由度的配准效果的差异。

## 2.2 损失函数

图像配准的效果由变换图像和固定图像之间的相似性度量来评估,常见的方法有相关性(CC)和互信息(MI)等,其中,CC 适用于具有线性关系的单模态图像配准,MI 适用于配准任何模态图像<sup>[10]</sup>。本文采用无监督的方案,没有变换参数的标签,所以不使用  $L1$  范式、 $L2$  范式等作为损失函数,而是采用了相似性度量的 CC 和 MI 作为损失函数来训练网络,分别用作单模态图像配准和多种不同模态图像配准。CC 可由如下公式计算求得:

$$CC(F, M) = \frac{\sum_{p_i} (F(p_i) - \hat{F}(p)) (M(p_i) - \hat{M}(p))}{\sum_{p_i} (F(p_i) - \hat{F}(p)) \sum_{p_i} (M(p_i) - \hat{M}(p))} \quad (3)$$

其中,  $F(p_i)$ 、 $M(p_i)$  分别表示固定图像和变换图像中第  $i$  个像素的值,  $\hat{F}(p)$ 、 $\hat{M}(p)$  分别表示固定图像和变换图像中全部像素的平均值。2 幅图像相似度越大,则相关性越大;图像完全相同,相关性等于 1。

MI 可由如下公式来运算求出:

$$I(A, B) = \sum_{a, b} p(a, b) \log \frac{p(a, b)}{p(a)p(b)} \quad (4)$$

其中,  $p(a, b)$  表示图像灰度值的联合分布;  $p(a)p(b)$  是独立情况下图像的联合分布;  $I(A, B)$  表示 2 个图像之间的相关性的度量,假设当图像正确对齐时,图像的灰度值之间存在最大的相关性<sup>[11]</sup>。

## 3 实验

### 3.1 实验环境

神经网络配准模型基于 Python 语言和深度学习框架 PyTorch 开发,该框架使用便捷,开发高效。模型运行的操作系统是 Windows 10,硬件环境是 Intel core i7 的 16 核处理器和 32 G 大小的内存存储器。

### 3.2 数据处理

实验采用开源数据集 BraTS,数据集服务于医学图像分割挑战赛,比赛目的是促进脑肿瘤的自动分割等技术的发展,本文用这些肿瘤患者的大脑 MRI 做配准实验。

从 BraTS2019 和 BraTS2021 中随机抽取了共 2 000 例患者的 MRI 数据,并只保留了 Flair、T1、T2 等 2 个模态的图像,其中 80% 作为训练集,20% 作为测试集。这些图像的背景数值都为 0,但是为了有利于数据处理,实验并未对图像做 mask 操作,而是做了中心裁剪,将图像统一裁剪为  $200 \times 200$  的大小,降低了背景比例。

在此基础上,将这些图像进行随机刚性变换生成移动图像。具体就是生成一个  $[-5, 5]$  内的弧度随机数,对图像做旋转操作,分别生成  $[-5, 5]$  内的像素横向位移随机数和纵向位移随机数,凭此再对图像做横向和纵向偏移,得到的结果图像就是训练和测试用的移动图像。

### 3.3 实验结果

实验发现仿射变换配准和刚性变换配准结果差异不大,刚性配准效果相对好一些,线性变换的参数只有  $\theta$ ,更容易收敛。用固定图像与变换图像的差值图像来表现配准效果,非常直观,为了保证背景差值的颜色为黑色,又对图像的差值矩阵取了绝对值。图 3 是一个能够反映配准效果的实例,第 1 列的图

是固定图像,第2列的图是移动图像,第3列是变换图像。最后一列的图是3个模态下固定图像与变换

图像的差值,可以观察到变换图像与固定图像差异很小。




图3 图像配准结果

Fig. 3 Results of image registration

实验结果表明,基于深度学习的刚性配准算法在不需要标签监督的情况下,可以有效地实现图像配准,而且相较于传统的配准算法,在速度方面获得了极大提升。

## 4 结束语

本文采用基于残差神经网络的无监督方法对大脑核磁共振图像进行刚性变换配准,通过残差网络的特征提取和全连接层的参数回归,有效映射了图像之间的刚性变换参数,从而实现了科学精准的图像配准。基于深度学习的方法与传统方法比较,配准速度也提高了数十倍。实验针对大脑核磁共振图像设计的配准方案,不适用于形变较大、又不规则的内脏器官,下一步将针对非线性变换图像配准展开研究,以提升网络模型的适用范围。

## 参考文献

- [1] ZITOVÁ B, FLUSSER J. Image registration methods: A survey [J]. *Image and Vision Computing*, 2003, 21(11): 977-1000.
- [2] MIAO Shun, WANG Z J, LIAO Rui. A CNN regression approach for real-time 2D/3D registration [J]. *IEEE Transactions on Medical Imaging*, 2016, 35(5): 1352-1363.
- [3] SALEHI S S M, KHAN S, ERDOGMUS D, et al. Real-time deep pose estimation with geodesic loss for image-to-template

rigid registration [J]. *IEEE Transactions on Medical Imaging*, 2018, 38(2): 470-481.

- [4] CHEE E, WU Zhenzhou. AIRNet: Self-supervised affine registration for 3D medical images using neural networks [J]. *arXiv Preprint arXiv*, 1810.02583, 2018.
- [5] 莫晓盈, 杨锋, 尹梦晓, 等. 医学图像配准的深度学习综述 [J]. *小型微型计算机系统*, 2021, 42(8): 1706-1714.
- [6] 黄鹏, 郭春生, 陈华华, 等. 基于深度学习的图像配准方法综述 [J]. *杭州电子科技大学学报*, 2020, 40(6): 37-44.
- [7] SOKOOTI H, VOS B D, BERENDSEN F, et al. Nonrigid image registration using multi-scale 3D convolutional neural networks [M]//DESCOTEUX M, MAIER-HEIN L, FRANZ A, et al. *Medical Image Computing and Computer-Assisted Intervention-MICCAI2017. Lecture Notes in Computer Science*. Cham: Springer, 2017, 10733: 232-239.
- [8] BALAKRISHNAN G, ZHAO A, SABUNCU M R, et al. VoxMorph: A learning framework for deformable medical image registration [J]. *IEEE Transactions on Medical Imaging*, 2019, 38(8): 1788-1800.
- [9] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, et al. Deep residual learning for image recognition [C]//*Proceedings of IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Piscataway, NJ: IEEE, 2016: 770-778.
- [10] 李雄飞, 张存利, 李鸿鹏, 等. 医学图像配准技术进展 [J]. *计算机科学*, 2010, 37(7): 27-33.
- [11] PLUIM J P W, MAINTZ J, VIERGEVER M A. Mutual-information-based registration of medical images: A survey [J]. *IEEE Transactions on Medical Imaging*, 2003, 22(8): 986-1004.