

基于 AI 技术的 CT 影像颅骨骨折智能检测临床研究

黄冬云 夏军^{通信作者}

(1 广州医科大学研究生院, 深圳市龙岗区第二人民医院医学影像科, 广东深圳 518001; 2. 深圳市第二人民医院医学影像科, 广东深圳 518001)

摘要: 随着计算机 AI 技术的突飞猛进及 CT 成像设备的普及化, 在医院工作量明显增大及精确诊断的情形下, 需对骨折患者进行快速精准的自动诊断。本文总结了基于放射影像的骨折智能诊断技术的发展; 并提出了一种基于深度学习卷积神经网络的颅骨骨折智能诊断算法, 并测试了算法的性能, 包括检出率 TPR 和 FPR。最后对该技术在医疗领域的应用价值以及面临的考验进行了展望。

关键词: CT; 颅骨骨折; 医学图像处理; 辅助诊断; 深度学习

1 前言

颅骨骨折发生断裂(一块或多块)情形被称为颅骨骨折。颅骨骨折通常由钝性冲击力引起。按部位骨折可以分为颅盖骨折、颅底骨折; 而按形态则可以分为线形、凹陷、粉碎几种; 同时按照破损程度又可以分为开放性 with 闭合性两种, 其中开放性只发生区域联通, 形成脑膜破裂甚至气颅或脑脊液泄漏。通常情况下, 如果骨折未导致颅骨结构发生太大改变则不需要特殊处理, 然而发生这些症状, 如血管破裂、脑或颅神经损伤, 脑膜撕裂等, 则需要及时就医处理^[1,2]。

在医学影像的分析和诊断中, 根据人体组织器官的特征、成像设备的物理原理对影像进行分析、模式确定、病灶信息提取等; 随着计算机视觉技术的发展, 对骨折的计算机智能自动检测技术也取得了极大的进步。在骨骼创伤自动检测领域, 3 个主要技术步骤是必须的: 医学图像处理(像源预处理)、特征提取和分类定位。目前的主要骨折产品集中在基于 x 射线图像自动检测骨折位置和形状, 评估骨折损失程度。在传统图像分析领域, 主要采用图像边缘检测、规则形状检测(如基于霍夫曼直线检测)等进行骨折患处检测, 同时还包括图像增强、线段测量、聚类等方法。然而由于骨折损伤的多样性和个体的差异性等因素, 目前开发的对各类骨折的快速检测技术仍存在不少误差, 性能也很不稳定^[3-8]。

将基于深度学习的 AI 技术应用到骨折诊断领域是目前学界的一个重要研究方向。目前在肋骨骨折、脊椎骨折、四肢骨折方面, 已经有相关报道, 同时市面上也出现了一些相关的产品。然而颅骨骨折方面缺鲜有报道, 这一方面是因为颅骨骨折形式复杂多样, 另一方面是因为颅骨的骨头分块多、结构复杂、缝隙多, 容易形成干扰。在本文中, 我们提出了一种基于深度学习的技术, 在 CT 颅骨断层影像上解决颅骨骨折患处检测的问题, 具有标注样本量需求少、检出率高、假阳少的特点^[9-18]。

2 方法

2.1 数据收集与分类标注

本研究中, 我们回顾性搜集本单位家医院共 200 例颅骨骨折患者的 CT 影像及诊断报告(获得当地伦理委员会批准免除患者知情同意权), 其中 150 例用于技术开发; 另外 50 例作为独立测试集测试算法模型, 以验证模型的准确性和鲁棒性。本研究中, 基于诊断报告, 我们征集 3 名放射影像专家依次对 200 例骨折 CT 影像进行标注, 内容包括: 骨折区域的勾画、骨折类型。其中颅骨骨折分为: 线性、凹陷。

2.2 图像预处理

我们共使用 4 台不同的 CT 扫描仪(Philips Brilliance 256 ICT; GE Optima 64; Philips Ingenuity 128; Siemens Definition Flash)进行 CT 断层扫描, 扫描范围从头项至脖子。扫描参数: 管电压 120kVP, 管电流 200-600mA, 取决于患者的头围, 重建层厚为 0.625 mm 或 1 mm, 骨算法。颅骨骨折图像从 PACS 系统中下载并存储为 DICOM 数据。所有数据由三名有经验的放射医师(8 年以上 CT 诊断经验)使用标注软件进行标注, 并进行交叉审核, 意见不一致时将进行共

同讨论协商以获得一致的最终诊断标准。使用开源的医疗的软件对数据进行脱敏并转化为 mha 的医学图像格式。

2.3 卷积神经网络构建

本文中我们提出了一种用于检测颅骨骨折的神经网络技术, 为了减少标注样本量, 我们采用先学习 landmark, 再学习骨折特征的技术, 由大至小逐步缩小检测范围, 由全局特征逐步聚焦到局部特征。通过这种技术可以减少对标注样本的需求, 提高算法的鲁棒性。

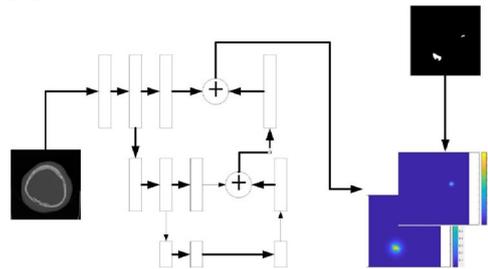


图 1 FCN 分割网络进行骨折位置热图回归

首先, 我们构建一个分割网络 FCN(Fully Convolutional Networks), 对骨折患处进行“热图回归”, 热力图和原 CT 图相比, 具有相同大小, 在热力图里, 越靠近骨折位置处像素值也越高, 反之则越来越小, 形成一个以骨折出为中心长条形或者圆形的光斑。因此, 需要构建一个基于医生标注的热图金标作为训练目标, 构建热力图采用高斯分布, 具体公式如下:

$$g_i(x, \sigma_i) = \frac{\gamma}{(2\pi)^{d/2} \sigma_i^d} \exp\left(-\frac{|x - x_i|_2^2}{2\sigma_i^2}\right) \quad (1)$$

其中, γ 是超参数, σ_i 是可学习参数, g_i 是表示第 i 个特征点对应的热力图。基于医生标注的骨折形状就可以构建对应的金标热力图。将分割网络 FCN 预测的热力图与金标做 loss 进行热图回归。Loss 函数定义为:

$$\text{loss} = \min_{w, b, \sigma} \sum_{i=1}^N \sum_x \|h_i(x; w, b) - g_i(x; \sigma_i)\|_2^2 + \alpha \|w\|_2^2 + \lambda \|\sigma\|_2^2 \quad (2)$$

在分割网络 FCN 预测的热力图中, 每个输出特征通道中都还有一个光斑, 其中光斑的中心(最亮的部分)就代表骨折患处。

通过上面的分割网络我们可以预测出骨折大致位置, 每个通道预测一处患处, 但是会存在一些问题, 比如一个通道同时存在多个光斑或者光斑比较模糊。所以需要将热图检测出的骨折大致位置输入到一个局部判断网络, 进一步识别骨折的细节, 这就是一个局部分割网络 LAN(Local Appearance Net), 与上个网络相比具比卷积核的尺寸更小, 只有 3 (FCN 的卷积核尺寸为 7)。将 FCN 的输出结果与 LAN 的输出结果相乘就可以得到细致的准确骨折的患处定位, 最后接一个分割模块就可以分割出骨折形状。

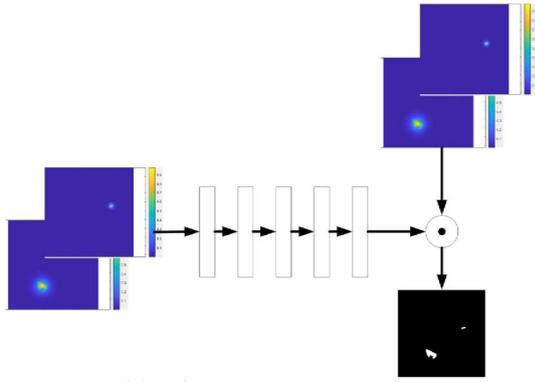


图 2 LAN 细分割骨折患处

3.实验与结果

我们设置学习率为 0.001, 采用 adam 优化器, 训练 1000-3000 个 epoch, 最后对结果进行测试, 我们的测试数据集有 50 个颅骨骨折 CT 数据, 将算法的预测结果与金标进行比较, 统计性能指标, 分析如下:

表 1 算法性能指标统计

Epoch	Dice	TPR	FPR
1000	0.817	0.871	0.236
2000	0.892	0.935	0.073
3000	0.901	0.941	0.072

可见, 随着训练深度的增加, 模型快速收敛, 训练 2000 个 epoch 后, loss 已经降低到足够低, 模型的性能开始稳定, 当达到 3000 个 epoch 时, 模型基本已经达到极限, 性能增加很少。因此, 我们采用 epoch=3000 的结果做为最终结果。最终的分割效果如图 3 所示。

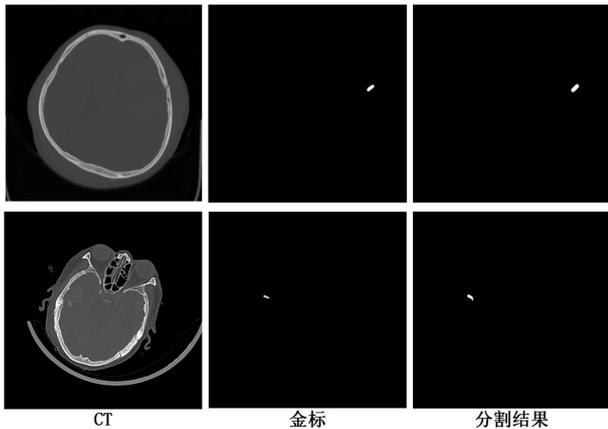


图 3 颅骨骨折分割的效果

4.结论

基于本文中提出的神经网络方法, 得到分割效果优秀, 且对标注的样本量需求少, 从实验中我么可以看出我们仅仅使用 150 例数据就训练出了一个分割 dice 达到 0.9 的模型, 训练的轮数仅仅数千轮就快速收敛了; 能取得如此效果, 原因如下:

基于整体的大致 ROI 检测, 目标区域是模糊的, 这样做一方面能克服其他区域的类似细节干扰模型, 另一方面又能在一定程度上克服金标中的误差, 具有模糊匹配的特性。

基于局部 LAN 的细节检测, 基于图 1 中的 ROI 区域进行检测, 输入只有局部信息, 能进一步聚焦骨折病灶的局部特征, 减少其他区域的特征干扰, 这样能大幅度减少数据需求。

这种从整体到局部, 从整体特征到局部特征的逐层检测, 能很好的克服干扰, 提炼有用的特征, 加速收敛。这也与医生的认知过

程相符, 即先找到 CT 图像中骨结构异常的区域, 再集中注意力到该异常区域, 进一步辨别异常的局部细节, 识别是否为骨折, 及骨折的类型。

5.展望

精确诊断颅骨骨折不仅辅助医生提高检出效率, 降低漏诊率, 减少医疗纠纷、帮助临床治疗提供决策依据。远期研究还可以进一步针对新鲜骨折、陈旧骨折进行自动判断, 同时还能用来进行骨折愈合的效果进行量化评估。

参考文献:

- 1、刘路, 陈明其, 卢瑞东. 螺旋 CT 三维重建在 20 例颅骨骨折诊治中的应用[J]. 贵州医药, 2009, 033(004):355.
- 2、王利君, 李家宏, 李晓明, 等. 颅骨骨缝与颅骨骨折鉴别诊断一例[C]// 中国法医学会法医临床学学术研讨会论文集.
- 3、陶开忠. 颅骨骨折的 CT 诊断及鉴别诊断[J]. 健康之路, 2013, 000(012):268-269.
- 4、陈祖蓉, 宋锦宏, 伍福强, 等. 64 排螺旋 CT 薄层横断及 VR 三维重建综合应用在颅骨骨折诊断中的价值[J]. 医学信息, 2013(25):58-58.
- 5、曹在民, 赵国权, 罗长青, 等. 多层螺旋 CT 容积扫描及三维重建在颅骨骨折诊断中的应用[J]. 临床军医杂志, 2012, 40(005):1246-1247.
- 6、谢新琳. CT 诊断颅骨骨折的价值分析[J]. 中国实用医药, 2007, 2(13):79-79.
- 7、刘端铭. 肋骨骨折在轴位 CT 图像上的定位诊断[J]. 解放军医药杂志, 2011, 23(002):55-57.
- 8、周清清, 王佳硕, 唐雯, 等. 基于卷积神经网络成人肋骨骨折 CT 自动检测和分类的应用研究[J]. 影像诊断与介入放射学, 2020, 029(001):27-31.
- 9、朱海云, 龚红伟. 骨折数字化 X 线自动诊断技术研究现状[J]. 中国数字医学, 2015(10):67-69.
- 10、郑伟. 基于混合推理的骨折智能诊断与治疗系统的研究[D]. 哈尔滨理工大学, 2005.
- 11、张春玲, 宋明军, 杜海涛, 等. 颅盖骨骨折 CT 图像的计算机自动分析研究[J]. 中国医学物理学杂志, 2013(06):4537-4542.
- 12、马娜. 骨折图像特征提取与分型识别技术研究[D]. 河北大学.
- 13、郑伟. 基于混合推理的骨折智能诊断与治疗系统的研究[D]. 哈尔滨理工大学, 2005.
- 14、S, Derkatch, C, 等. 采用卷积神经网络识别脊柱骨折来预测非椎体和髋部骨折:基于双能 X 线吸收的登记队列研究[J]. 国际医学放射学杂志, 2020, v.43(01):112-112.
- 15、C.T.Cheng, T.Y.Ho, T.Y.Lee, 等. 深度学习算法在骨盆平片中检测髋部骨折的应用[J]. 国际医学放射学杂志, 2019, v.42(06):123-123.
- 16、Kalmet PHS, Sanduleanu S, Primakov S, Wu G, Jochems A, Refaee T, Ibrahim A, Hulst LV, Lambin P, Poeze M. Deep learning in fracture detection: a narrative review. Acta Orthop. 2020 Apr;91(2):215-220. doi:
- 17、Lindsey, R., et al. (2018). "Deep neural network improves fracture detection by clinicians." Proceedings of the National Academy of Sciences 115((Kim and MacKinnon 2018)45): 11591.
- 18、Kim, D. H. and T. MacKinnon (2018). "Artificial intelligence in fracture detection: transfer learning from deep convolutional neural networks." Clinical Radiology 73(5): 439-445.