

· 综述 ·

深度学习在麻醉学研究中的应用进展

王悠然 陈利海 葛亚力

【摘要】 随着医学技术的发展,麻醉科医师的工作范围拓展至围术期各个阶段,从而保障患者的生命安全和提供舒适化医疗。然而围术期的影响因素众多,麻醉科医师人员紧缺又易疲劳,难以满足日益增长的临床需求。自生物医学进入大数据时代后,医学数据增长速度已远快于传统人工分析数据的速度,传统算法已不适用于处理海量的医学数据,因此,深度学习开始发挥它的作用。本文就深度学习在麻醉学研究中的应用做一详细描述。

【关键词】 深度学习;麻醉学;疾病预测;超声引导

Progress of deep learning in anesthesiology WANG Youran, CHEN Lihai, GE Yali. Department of Anesthesiology, Nanjing First Hospital, Nanjing Medical University, Nanjing 210006, China
Corresponding author: GE Yali, Email: ge_y_l@163.com

【Abstract】 With the development of medical technology, the work of anesthesiologists has expanded to protect life safety and provide comfort of patients at all stages of the perioperative period. However, the influencing factors during the perioperative period are complicated. Anesthesiologists are short-staffed and overloaded with work, which makes it difficult to meet the increasing clinical needs. Since biomedicine entered the era of big data, the growth rate of medical data has been much faster than that of traditional manual analysis of data. Traditional algorithms are no longer suitable for processing massive medical data. Therefore, deep learning technique begins to play its role. This article gives a review of the application of deep learning in anesthesiology.

【Key words】 Deep learning; Anesthesiology; Disease prediction; Ultrasound-guided

随着医学技术的发展,麻醉科医师的工作已由仅在手术过程中稳定患者生命体征转变为在围术期各个阶段保障患者的生命安全和提供舒适感受。个体化麻醉管理可满足转变的工作需求,但实施过程需要麻醉科医师综合考虑多种因素,诊断时间长;且麻醉科医师紧缺又易疲劳,难以支持日益增长的临床需求。既往研究者利用传统统计学算法和传统机器学习算法分析病例数据^[1],但传统算法也需人工参与,且仅在数据量较少时效果优良,当数据量增长至一定程度时,准确率下降。随着生物医学进入大数据时代^[2],如今的医学数据增长速度已远快于传统人工分析数据的速度^[3],传统算法已不适用于处理海量的医学数据,因此,深度学习开始发挥它的作用。本文就深度学习在麻醉学研究中的应用进展作一综述。

深度学习概述

深度学习首次由 Hinton 等^[4]于 2006 年在《科学》杂志上提出,它是模拟人脑构建的一种新型机器学习模型,包括输入层、隐层及输出层三层网络结构,“深度”是指模型中包

含了两个及以上的隐层,深度学习可将简单的低级特征组合为抽象的高级表示,其拟合复杂而抽象的高级特征的能力优于传统机器学习模型,不仅在处理大型且复杂的数据(如连续监测数据)问题上具有良好的适用性,还可自主学习数据规律,大大减少了人力成本,可将临床医师从繁重的工作中解放出来。近年来深度学习已应用于生物医学中的疾病诊断、图像识别与处理、基因组学等多个方面^[3]。

深度学习在超声中的应用

超声已成为麻醉科医师诊断与操作的一大利器,神经阻滞、术中超声心动图监测、困难动静脉置管等都需要超声辅助。对超声图片的准确识别是麻醉科医师掌握超声技术的基础。卷积神经网络(convolutional neural networks, CNN)是深度学习的代表算法之一,它的运算模式类似于人眼感受外界,首先通过逐层拆解图像获得局部感受野,再计算每个感受野内单个像素点的 RGB 值,后整合各局部感受野的信息以识别整张图像内容。随着运算函数的不断革新,运算速度大幅增长。如今, CNN 算法已可以快速进行图像识别工作,对图像识别的准确性也可与人类肉眼相当。CNN 在医学影像学中的发展十分迅速,在超声中的应用更是大大提高了麻醉科医师的工作效率并减轻了其工作负担。

超声心动图图像的识别 心脏手术中常规使用经食管

DOI:10.12089/jca.2021.07.020

作者单位:210006 南京医科大学附属南京医院(南京市第一医院)麻醉科

通信作者:葛亚力, Email: ge_y_l@163.com

超声心动图(transesophageal echocardiography, TEE)对心功能进行监测,TEE 能从形态和功能两个方面评估循环系统,具有定位、定性、定时、定量的基本功能,为术中麻醉科医师的诊疗决策提供依据,提高麻醉和手术的安全性^[5]。

Andreassen 等^[6]采用 195 250 张 TEE 图像构建了一种 CNN 模型,用于自动定位二尖瓣环位置,该模型得出的平均误差仅为 2.0 mm,可用于辅助临床诊断二尖瓣相关疾病及制定干预措施。蒋建慧等^[7]基于 CNN 模型构建出一种可自动计算左室射血分数(left ventricle ejection fractions, LVEF)的方法,此模型分割的左室内膜轮廓与人工分割进行对比后,相似率高达 96.8%,真阳性率达 88.8%,所计算的 LVEF 误差率也仅为 0.038 947,提高了计算机快速诊断的准确性。这些研究预示着未来深度学习用于术中辅助诊断的可能,为麻醉和手术的安全提供保障。

超声引导下神经阻滞 随着技术的进步与经济的发展,超声引导下的神经阻滞依靠其可视、安全性高等优势逐渐替代传统的盲穿和神经刺激器引导的神经阻滞,成为神经阻滞麻醉的主要方法。准确的神经追踪是进行安全有效阻滞的关键。Alkhatib 等^[8]构建了 13 种基于 CNN 设计的神经追踪器,用于识别超声图像中的正中神经和坐骨神经两种神经,研究者评估了全部追踪器的性能,并与传统的自适应中值二进式模式进行比较,结果表明基于 CNN 构建的追踪器在识别正中神经时精确度最高达 95%,识别坐骨神经时最高达 72%,传统模型对两种神经识别的精确度仅为 84%和 64%,远低于 CNN 模型。龙法宁等^[9]设计出可自动识别臂丛神经的 CNN 模型,模型描绘出的图像较手动描图具有更高的准确性,可为麻醉科医师提供安全有效的神经定位指导,减少误判的发生以及降低局麻药中毒、神经损伤等并发症的发生率。此类模型还可在将来拓展应用于其他神经的识别,不仅能使人工神经阻滞更加安全,还可为将来使用机器人进行神经阻滞麻醉提供技术支持。

超声引导下蛛网膜下腔阻滞 医师操作不熟练或患者自身情况不佳(如肥胖、老年、腰椎疾病等)都会增加穿刺的失败率,并发症的发生率也随之增高。Pesteie 等^[10]构建了一种用于自动识别超声下硬膜外腔并确定针靶位置的 CNN 模型,研究者将计算机与人工标记的靶点分别在 2D 和 3D 图像上进行对比,结果表明计算机定位的靶点与人工标记点在 2D 图像上的水平与垂直误差仅为 1 mm 和 0.4 mm,在 3D 图像中的误差仅为 1.7 mm 和 0.8 mm。因此,以深度学习模型指导针靶定位,或可减少因定位错误、注药位置偏差等导致的麻醉效果不佳、反复穿刺性损伤及其他并发症的发生。

深度学习在围麻醉期的应用

随着预测模型的发展,深度学习已应用于围麻醉期各个阶段的研究工作。常见的深度学习预测模型有:深度置信网络、自动编码器和循环神经网络等。

监测麻醉深度 手术中既要避免麻醉过浅又要防止麻醉过深,过浅可能发生术中知晓,过深又易影响患者转归,两

者都会对患者的生理心理造成损害,且手术不同阶段的应激程度不同,需要不断调整麻醉深度以适应手术刺激,工作量大。因此,如何判断患者的麻醉深度及适时调节麻醉药用量,一直是麻醉科医师关注的问题。

Lee 等^[11]共纳入了 927 104 个时点的数据样本作为训练集,首次用深度学习中的长短期记忆算法(long-short term memory, LSTM)预测靶控输注丙泊酚和瑞芬太尼时的 BIS 变化,该模型将预测结果的一致性相关系数从传统模型的 26.5%提升至 56.1%,极大地提高了 BIS 预测的准确率;该研究可为麻醉科医师提供一个预警系统:在 BIS 出现过高或过低趋势时提醒麻醉科医师及时调整丙泊酚及瑞芬太尼的输注速率,以确保麻醉深度在一个合适的范围内,有助于患者术后快速苏醒和减少麻醉后并发症的发生。在此之后,Li 等^[12]又将 LSTM 与模糊自动编码器相结合,利用麻醉期脑电图的变化预测麻醉深度。与其他传统预测模型相比,此模型预测准确率最高,达 85.56%;此模型既能避免麻醉过深增加术后并发症的发生,又可避免出现术中知晓,有望在临床中推广应用。将来在此方面的研究目标是:构建的深度学习模型不仅可以预测术中麻醉深度,还可根据麻醉深度的变化趋势自动调节麻醉药用量,这将大大缩减麻醉深度异常的时间,更好地保障患者的生命健康,同时解放麻醉科医师,使其更关注于处理患者的其他突发情况。

预测围麻醉期疼痛 避免患者术中疼痛是麻醉科医师的重要任务,多种麻醉药的复合应用往往会掩盖疼痛的典型表现,使麻醉科医师无法及时发现患者镇痛不足,造成患者严重的生理及心理创伤。Lim 等^[13]构建了一套用于评估术中疼痛程度的深度学习模型,将术中采集的心率及其变异性等数据导入 3 种算法中:深度置信网络(deep believe network, DBN)、多层感知机和支持向量机,3 种预测模型的准确率由 ROC 曲线下 AUC 面积进行评估,结果表明 DBN 准确率最高,达 84.1%。该模型的建立有望在未来为手术患者开发出一种疼痛评估系统,以预防术中镇痛不足的情况发生。

随着“无痛诊疗”理念的兴起,无痛医疗成为主流。疼痛管理的首要问题是识别疼痛,由于个体差异,不同患者对于疼痛的耐受程度不尽相同,同样的镇痛方案并不适用于所有人群,而患者数量越来越多,紧缺的麻醉科医师无法同时顾及所有的患者,再加上患儿、神经系统疾患等言语障碍者无法准确表达疼痛感受,易延误诊断。Kharghanian 等^[14]用卷积深层置信网络对面部表情特征进行识别,用来判断患者是否存在疼痛,所得结果准确率高达 95%,可降低疼痛漏诊的发生率。Rodriguez 等^[15]建立了一种 CNN+LSTM 模型用于指导制定术后镇痛方案,该复合模型先利用 CNN 算法提取图像中的面部特征,再用这些面部特征数据训练 LSTM 算法进行疼痛分级,对疼痛级别的估计准确率高达 97.2%。通过识别面部表情判断患者疼痛与否和对疼痛分级为未来评估术后疼痛并及时给予止痛措施提供了准确可靠的方法,不仅促进了舒适医疗的发展,还可减少麻醉科医师的工作量。

预测术后并发症 Lee 等^[16]纳入不同的风险因素预测肝移植术后急性肾损伤(acute kidney injury, AKI)的发生情况,并研究不同算法预测 AKI 的准确率和灵敏度,结果表明,与传统的 Logistic 回归及深度学习模型相比,传统机器学习算法的结果更优。这可能是因为该试验仅纳入了 1 211 例患者,样本量过小。由于深度学习模型更适用于大数据样本,因此该试验不能充分发挥深度学习的效能。Meyer 等^[17]研究纳入了 11 492 例心脏直视手术患者,选择术前、术中及术后的危险因素,并用于训练循环神经网络,获得了一个可预测术后严重出血、肾衰竭及死亡率的深度学习模型,该模型预测的准确率均优于传统算法,可辅助医师早期诊断、早期干预,提高手术的安全性。

预测术后死亡率 Fritz 等^[18]建立了一种多路径卷积神经网络模型,用于自动提取术中生命体征,预测术后死亡率,不仅预测结果优于支持向量机和 Logistic 回归模型(3 种模型的准确率分别为 86.7%、83.6%和 83.7%),而且该模型所采集的是术中随机时间点的数据,因此可在术中实时监测术后死亡相关危险因素,并及时提醒医生给予干预措施,以降低术后死亡率,同时减少其他并发症的发生。

深度学习的不足

深度学习模型存在几个主要缺点。首先是训练过程不透明,无法获取数据分析的具体过程,且难以解释所得结果,即存在“黑匣子”现象^[19]。其次,训练深度学习模型需要大小可观的数据集,而临床试验的数据大多无法满足所需训练数量,易出现过拟合现象;所获得的模型无法描述问题的真实分布^[19]。此外,深度学习算法的准确度还会受到原始数据偏倚的影响(如样本量大小、盲法产生的偏倚等)^[20]。

小 结

深度学习是当下最流行的人工智能算法,它改良了计算函数,使其较传统机器学习算法处理数据速度更快更准确,尤其是在大规模数据处理时准确度更优。现阶段深度学习的主要优点体现在在保证围术期患者生命安全的同时,大大减轻了麻醉科医师的工作量,除了本文已列出的应用之外,未来深度学习算法还可考虑用于预测围术期低血压、心律失常、心脏骤停及术后多种并发症的发生。深度学习在将来必然会进一步发展,更好地辅助麻醉科医师的工作。

参 考 文 献

- [1] 巨荣辉. 基于深度学习和医疗数据的疾病提前诊断和风险预测方法研究. 武汉: 华中科技大学, 2018.
- [2] 洪浩, 伯晓晨, 李非. 深度学习在生物医学数据中的应用. 医学信息学杂志, 2018, 39(3): 1-9.
- [3] Miotto R, Wang F, Wang S, et al. Deep learning for healthcare: review, opportunities and challenges. Brief Bioinform, 2018, 19(6): 1236-1246.
- [4] Hinton GE, Salakhutdinov RR. Reducing the dimensionality of data with neural networks. Science, 2006, 313(5786): 504-507.
- [5] Jaidka A, Hobbs H, Koenig S, et al. Better with ultrasound: transesophageal echocardiography. Chest, 2019, 155(1): 194-201.
- [6] Andreassen BS, Veronesi F, Gerard O, et al. Mitral annulus segmentation using deep learning in 3-D transesophageal echocardiography. IEEE J Biomed Health Inform, 2020, 24(4): 994-1003.
- [7] 蒋建慧, 姚静, 张艳娟, 等. 基于深度学习的超声自动测量左室射血分数的研究. 临床超声医学杂志, 2019, 21(1): 70-74.
- [8] Alkhatib M, Hafiane A, Vieyres P, et al. Deep visual nerve tracking in ultrasound images. Comput Med Imaging Graph, 2019, 76: 101639.
- [9] 龙法宁, 朱晓姝, 甘井中. 基于卷积神经网络的臂丛神经超声图像分割方法. 合肥工业大学学报(自然科学版), 2018, 41(9): 1191-1195, 1296.
- [10] Pesteie M, Lessoway V, Abolmaesumi P, et al. Automatic localization of the needle target for ultrasound-guided epidural injections. IEEE Trans Med Imaging, 2018, 37(1): 81-92.
- [11] Lee HC, Ryu HG, Chung EJ, et al. Prediction of bispectral index during target-controlled infusion of propofol and remifentanyl: a deep learning approach. Anesthesiology, 2018, 128(3): 492-501.
- [12] Li R, Wu Q, Liu J, et al. Monitoring depth of anesthesia based on hybrid features and recurrent neural network. Front Neurosci, 2020, 14: 26.
- [13] Lim H, Kim B, Noh GJ, et al. A deep neural network-based pain classifier using a photoplethysmography signal. Sensors (Basel), 2019, 19(2).
- [14] Kharghanian R, Peiravi A, Moradi F. Pain detection from facial images using unsupervised feature learning approach. Annu Int Conf IEEE Eng Med Biol Soc, 2016, 2016: 419-422.
- [15] Rodriguez P, Cucurull G, Gonzalez J, et al. Deep pain: exploiting long short-term memory networks for facial expression classification. IEEE Trans Cybern, 2017.
- [16] Lee HC, Yoon SB, Yang SM, et al. Prediction of acute kidney injury after liver transplantation: machine learning approaches vs. logistic regression model. J Clin Med, 2018, 7(11): 428.
- [17] Meyer A, Zverinski D, Pfahringer B, et al. Machine learning for real-time prediction of complications in critical care: a retrospective study. Lancet Respir Med, 2018, 6(12): 905-914.
- [18] Fritz BA, Cui Z, Zhang M, et al. Deep-learning model for predicting 30-day postoperative mortality. Br J Anaesth, 2019, 123(5): 688-695.
- [19] Akay A, Hess H. Deep learning: current and emerging applications in medicine and technology. IEEE J Biomed Health Inform, 2019, 23(3): 906-920.
- [20] Hashimoto DA, Witkowski E, Gao L, et al. Artificial intelligence in anesthesiology: current techniques, clinical applications, and limitations. Anesthesiology, 2020, 132(2): 379-394.

(收稿日期: 2020-05-26)