

机器学习 CNN 模型在心血管疾病诊疗中的临床应用及研究进展

艾克力亚尔·艾尼瓦尔¹ 马翔^{1,2}

(1.新疆医科大学研究生院,新疆 乌鲁木齐 830054; 2.新疆医科大学第一附属医院,新疆 乌鲁木齐 830054)

【摘要】近年来随着计算机技术的发展,机器学习领域的发展越来越迅速,因其具有模仿人脑解释数据的功能,借助计算机强大的整合数据的能力,被广泛地应用于临床,为疾病的诊断、预后分析、诊疗决策的制定等方面提供了方便。现简要概述用于构建推论和预测数据驱动的 CNN 模型在心血管疾病诊疗中的临床应用及研究进展,分析该模型在心血管疾病应用上的优势以及不足。

【关键词】机器学习;深度学习;卷积神经网络;心血管疾病

【DOI】10.16806/j.cnki.issn.1004-3934.2021.06.003

Application of Convolutional Neural Network Model of Machine Learning for Diagnosis and Treatment of Cardiovascular Diseases

Aikeliyaer · Ainiwaer¹, MA Xiang^{1,2}

(1.Xinjiang Medical University Graduate School, Urumqi 830054, Xinjiang, China; 2.The First Affiliated Hospital of Xinjiang Medical University, Urumqi 830054, Xinjiang, China)

【Abstract】 In recent years, with the development of computer technology, the field of machine learning is developing more and more rapidly. With the function of imitating human brain to interpret data and the powerful ability of computer to integrate data, machine learning has been widely used in clinical practice, which provides convenience for prognosis analysis, diagnosis and treatment of diseases. In this review, we briefly summarized the clinical application and research progress of the machine learning CNN model used to construct inference and prediction data-driven model in the diagnosis and treatment of cardiovascular diseases, and analyzed its advantages and disadvantages in the application of cardiovascular diseases.

【Key words】 Machine learning; Deep learning; Convolutional neural network; Cardiovascular diseases

人工智能自 20 世纪 60 年代提出以来,发展迅速,机器学习作为实现人工智能的方法,用来解析和学习数据,通过算法完成数据整合任务。深度学习是目前最前沿的机器学习模型,其独有的自动提取特征的特点,使人工算法为临床所用。中国心血管病人群庞大,临床医生数量缺口大,往往无法满足患者就医需求,因此机器学习被应用到心血管疾病诊疗中。

1 机器学习

1.1 机器学习概述

机器学习近年来被广泛应用在临床诊疗中。深度学习属于机器学习的一种,通过“黑匣子”^[1]自动学习数据的特征和关系,在阅读医学图像数据,诊断疾病及疾病危险分层等方面具有巨大潜力^[2-3]。

机器学习通过组成简单但非线性的模块来获得,

每个模块将一个层次的信息转换为一个更高、稍微抽象的层次的表示。在临床常应用的模型是卷积神经网络(convolutional neural network, CNN)模型^[4-5],应用于 X 射线、CT、MRI 和超声心动图等影像学检查,也可用于心电图的辅助诊断^[6-9]。其识别图像的基本步骤为:识别图像特征,图像分类,对图像进行分割,评估图像形态结构的测量和量化、识别图像^[10]。

1.2 CNN

CNN 是一类指导学习网络,可以自主感知输入与输出之间的映射关系,从而分析和处理数据^[11]。为了建立 CNN 模型,需要收集大量临床信息、影像学资料和随访资料,并根据资料特征分类。以影像学资料为例,在训练过程中(见图 1),CNN^[4]模型首先会看到一幅图像即输入层,计算机理解为输入若干个矩阵,会把

图片光栅化,以像素形式存在,并以分数向量的形式输出结果,进入卷积层,通过多个可训练的滤波器和加权偏置进行卷积,卷积后进入池化层产生若干个映射图,特征映射图中每组多个像素进行求和、加权值和加偏置,紧接着通过一个函数得到多个下一层的特征映射,并通过与上一层相同的方法产生下一层映射,每一层都可提取上一层的局部特征,局部特征的确定意味着两层间关系的确立,最终通过特定排列检测图像边缘,将图案组合匹配更大的图案组合得到输出结果^[12]。

卷积层与池化层的组合可以在隐藏层出现很多次,出现次数是根据模型的需要而来的。选取的函数是根据对默认参数和二进制交叉熵的要求来进行选定,常用函数有 RELU 函数和 sigmoid 函数等。最后一次池化结束后,进入全连接层,将分布式特征映射到样本标记空间,实现对图形分类并输出结果。以上就是 CNN 模型对影像学资料深度学习的基本流程,对于临床资料的学习,可省去图片光栅化的过程,后面的流程与影像学资料学习过程一致。




图 1 CNN 模型示意图

2 在心血管疾病方面的应用

2.1 在辅助检查的应用

2.1.1 CT

CT 在临床上常用于先天性心脏病、主动脉夹层 and 冠心病等的诊断,然而主要为二维成像,且心脏具有特殊结构,导致 CT 扫描无法显示清楚,对临床诊断造成干扰。Tatsugami 等^[13]通过深度学习混合迭代重建方法改善冠状动脉 CT 血管成像图像质量,Bruns 等^[14]使用深度学习模型,在冠状动脉 CT 血管成像中进行全心分割,量化心脏测量结果。深度学习模型通过训练大数据,对图片上极小的像素位置差异进行识别,也可优化影像学资料,为疾病的诊断提供极大的帮助。

2.1.2 超声心动图

超声心动图是利用超声技术获取心脏及其周围结构的高时空分辨率图像,然而心脏的结构复杂,图像固有的斑点噪声,超声图像相位及心脏轮廓模糊等因素,为临床诊疗带来不便。CNN 模型可对超声心动图进

行合适的分割^[15],自动测量左室射血分数,对心尖二腔切面和心尖四腔切面进行准确分割,并可识别节段性室壁运动异常^[16],且判读能力优于低年资医生,并达到专家水平。该模型^[17]甚至可以通过超声心动图自动检测肥厚型心肌病、心脏淀粉样变和肺动脉高压(见表 1)。

2.1.3 心电图

心电图是一种常用诊断心血管疾病的工具,但偶尔会发生漏读或误读^[18]。近年来,不少研究通过深度学习模型阅读心电图^[19]。心电图的自动分析依赖于两阶段的方法,首先需要人根据原始心电数据提取特征^[20],然后部署决策规则或其他机器学习方法来生成最终结果。心电图还具有容易受干扰的特点,因此去噪成为了深度学习所要克服的另一大难题。Zhao 等^[21]采用了一种广泛应用的深度学习技术来进行心电去噪。除此之外,心电图具有一维图像的特点,分类常用的 CNN 有两种:一维 CNN^[22]和二维 CNN^[23]。这

些模型可以做到心律失常的检测^[24-25]和分析 ST 段的变化^[26]。深度学习模型擅长阅读二维的图片如 CT 和 MRI 等,由于心电图的特殊性,往往需要必要的手段对图片进行加工或使用专用模型才能阅读。由于这些因

素的限制,目前的手段只能让深度学习模型阅读简单的心电图结果,随着计算机科学的发展,在不久的将来会出现适合阅读复杂心电图的深度学习模型。

表 1 CNN 模型辅助检查利用

作者及年份	应用	结论
Tatsugami 等 ^[13] , 2019 年	CT	CNN 提高了冠状动脉 CT 血管成像的图像质量
Bruns 等 ^[14] , 2019 年	CT	CNN 模型实现了对 CT 扫描图像准确的全心分割
蒋建慧等 ^[15] , 2019 年	超声心动图	CNN 自动测量左室射血分数的方法较传统方法更好
Kusunose 等 ^[16] , 2020 年	超声心动图	CNN 通过超声心动图自动诊断室壁运动异常
Zhang 等 ^[17] , 2018 年	超声心动图	CNN 可实现自动阅读超声心动图
Belo 等 ^[20] , 2020 年	心电图	CNN 模型可识别心电图特征
Zhao 等 ^[21] , 2019 年	可穿戴设备心电图	CNN 模型可识别期前收缩

2.2 在心血管疾病危险分层的应用

在日常对心血管疾病的诊疗过程中,对心血管疾病的危险分层尤为重要,临床上常使用 TIMI 评分、GRACE 评分及 ACTION 评分,然而传统评分过分依赖于实验室指标,往往无法早期评估病情^[27]。心血管疾病治疗方法的发展,以及新的心血管药物的出现对心血管疾病的危险分层带来新的挑战,因此,借助深度学习模型探索心血管疾病危险分层的新方法成为近年来的热点(见表 2)。Kwon 等^[28]对急性心肌梗死患者的数据进行分析,使用 CNN 模型对其危险度进行分层(DAMI 评分)的表现与 GRACE 评分、ACTION 评分以及 TIMI 评分进行了比较。结果发现模型评估 ST 段抬高心肌梗死和非 ST 段抬高心肌梗死危险分层的能力

明显优于这三种评分。除此之外,在 6 个月的随访中,由 DAMI 定义的高危组的死亡率显著高于低危组。Huo 等^[29]提出了一个机器学习模型,通过分类分析将以往确诊和误诊的主动脉夹层进行分类,可帮助医师快速发现所有误诊的主动脉夹层阳性患者,评估入院后病情进展。通过对实际病例数据的训练,该预测模型可以确定患者的优先等级。深度学习参与对心血管疾病危险分层准确性更高,但在一定程度上依赖于心血管医生对患者临床信息的掌握,准确及全面的疾病信息可以使深度学习模型发挥出更好的作用。传统评分已通过大量临床病例考验并沿用至今,深度学习模型病例数较少,还需要大量临床实践验证其临床实用性。

表 2 疾病风险估计及预后预测

作者及年份	应用	结论
Kwon 等 ^[28] , 2019 年	预测疾病风险	机器学习模型预测急性心肌梗死患者的住院死亡率和 12 个月死亡率较准确
Huo 等 ^[29] , 2019 年	预测疾病风险	对主动脉夹层患者进行早期分类和预测具有较好的表现
Wu 等 ^[31] , 2019 年	疾病诊断	该机器学习模型能较好预测非 ST 段抬高心肌梗死患者
Kwon 等 ^[32] , 2018 年	预测疾病预后	机器学习准确地预测了急性心力衰竭患者的死亡风险
Commandeur 等 ^[34] , 2019 年	预测疾病预后	机器学习可预测心肌梗死的长期风险

2.3 在评估心血管疾病预后的应用

心血管疾病一级预防的关键策略是“预测”,以往用来预测心血管疾病的手段甚少,常用的心血管疾病预测手段也并非十分准确^[30]。深度学习模型可以发现临床医生无法察觉的细微病情变化,并使用大数据模型很好地预测病情。Wu 等^[31]收集了急诊就诊的胸痛患者的数据,建立一个深度学习模型来预测患者的非 ST 段抬高心肌梗死。Kwon 团队^[32]借助深度学习模型对心力衰竭患者进行预后分析的一项研究发现,与现有的风险评分和其他机器学习模型相比,他们的这个模型能更准确地预测急性心力衰竭患者的住院和长期死亡率。Zack 等^[33]为了确定深度学习模型是否

可以更好地预测经皮冠状动脉介入治疗后存在死亡或充血性心力衰竭再住院风险,评估了 11 709 例不同的患者,研究发现深度学习模型具有更好的预测能力。Commandeur 等^[34]在一项前瞻性研究中用 CNN 模型评估了心外膜脂肪组织,评估冠状动脉钙化分数,并纳入了必要的临床指标,将这些临床资料用来训练机器学习模型,用模型给受试者评分,将得分与动脉粥样硬化风险评分相比较,发现机器学习评分有更好的预测能力。心血管疾病具有发病迅猛的特点,因此通过心血管疾病危险因素预测心血管疾病的发生尤为重要,以往只能通过疾病危险因素来判断疾病发生的可能性,将深度学习模型引用到疾病预测的手段当中,可以

量化疾病风险,甚至可以提前发现最危险因素,并在未病阶段进行有效干预,为疾病治疗赢取时间。然而,深度学习模型需要依赖检查结果,无法像人那样仅根据临床表现对疾病预后进行评估,该模型目前阶段仅适用于可以完善初期检查的病情变化较缓慢的疾病。

3 总结与展望

使用机器学习模型对各类心血管疾病的诊断以及评估是一种非常客观的方法,在模型训练准确的情况下,不会出现因评估医生能力不同而产生误差的情况,且这类模型对各种辅助检查图像的改善、图像的解读、心电图的阅读具有优秀表现。模型对疾病轻重缓急可以进行迅速评估,准确度普遍高于传统的评分标准,为临床治疗赢取时间。模型还可以减少临床医生的负担,提升基层医院诊断水平。深度学习模型另一个潜在应用可以将实时图像与之前影像学检查的图像进行自动比较,从而使解读的医生能够更直观地了解疾病进程。

然而,目前的模型还需更多的试验去验证,深度学习的方法是一个“黑匣子”,无法准确了解计算机模型中各个临床指标的实际作用,这种未知因素会带来一定的风险甚至会带来医疗纠纷。深度学习模型的建立往往需要大量的临床资料,而由于罕见病临床资料较少,因此机器学习模型可能无法适用于罕见病。模型对录入数据要求高,如果输入的数据质量较差或有偏差,解释的质量也会较差,此外,必须强调创建数据的统一标准,从而允许不同算法之间的集成,允许算法在不同的设备上运行。

2020 年,谷歌的研究人员^[35]宣布已找到破解深度学习“黑匣子”的方法,也许在不久的将来,深度学习模型会变得更加安全,机器学习将来仍是一种不可忽视的辅助医疗力量,其现有的缺点也将会渐渐被改进。

参考文献

- [1] Lee G, Fujita H. Deep learning in medical image analysis: challenges and applications[M]. Berlin, Germany: Springer International Publishing, 2020: 18-19.
- [2] Lin S, Li Z, Fu B, et al. Feasibility of using deep learning to detect coronary artery disease based on facial photo[J]. *Eur Heart J*, 2020, 41(46): 4400-4411.
- [3] Avram R, Olgin JE, Kuhar P, et al. A digital biomarker of diabetes from smartphone-based vascular signals[J]. *Nat Med*, 2020, 26(10): 1576-1582.
- [4] Srinivasan S, Greenspan RJ, Stevens CF, et al. Deep(er) Learning[J]. *J Neurosci*, 2018, 38(34): 7365-7374.
- [5] LeCun Y, Bengio Y, Hinton G. Deep learning[J]. *Nature*, 2015, 521(7553): 436-444.
- [6] Kolossváry M, de Cecco CN, Feuchtnner G, et al. Advanced atherosclerosis imaging by CT: radiomics, machine learning and deep learning[J]. *J Cardiovasc Comput Tomogr*, 2019, 13(5): 274-280.
- [7] Lundervold AS, Lundervold A. An overview of deep learning in medical imaging focusing on MRI[J]. *Z Med Phys*, 2019, 29(2): 102-127.
- [8] Gandhi S, Mosleh W, Shen J, et al. Automation, machine learning, and artificial intelligence in echocardiography: a brave new world[J]. *Echocardiography*, 2018, 35(9): 1402-1418.
- [9] Khatibi T, Rabinezhadsadatmahaleh N. Proposing feature engineering method based on deep learning and K-NNs for ECG beat classification and arrhythmia detection[J]. *Australas Phys Eng Sci Med*, 2019 Nov 26. DOI: 10. 1007/s13246-019-00814-w.
- [10] Kusunose K. Radiomics in echocardiography: deep learning and echocardiographic analysis[J]. *Curr Cardiol Rep*, 2020, 22(9): 89.
- [11] Rawat W, Wang Z. Deep convolutional neural networks for image classification: a comprehensive review[J]. *Neural Comput*, 2017, 29(9): 2352-2449.
- [12] Schwendicke F, Golla T, Dreher M, et al. Convolutional neural networks for dental image diagnostics: a scoping review[J]. *J Dent*, 2019, 99(7): 769-774.
- [13] Tatsugami F, Higaki T, Nakamura Y, et al. Deep learning-based image restoration algorithm for coronary CT angiography[J]. *Eur Radiol*, 2019, 29(10): 5322-5329.
- [14] Bruns S, Wolterink JM, Takx RAP, et al. Deep learning from dual-energy information for whole-heart segmentation in dual-energy and single-energy non-contrast-enhanced cardiac CT[J]. *Med Phys*, 2020, 47(10): 5048-5060.
- [15] 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[J]. *临床超声医学杂志*, 2019, 21(1): 70-74.
- [16] Kusunose K, Abe T, Haga A, et al. A deep learning approach for assessment of regional wall motion abnormality from echocardiographic images[J]. *JACC Cardiovasc Imaging*, 2020, 13(2 Pt 1): 374-381.
- [17] Zhang J, Gajjala S, Agrawal P, et al. Fully automated echocardiogram interpretation in clinical practice feasibility and diagnostic accuracy[J]. *Circulation*, 2018, 138(16): 1623-1635.
- [18] Liu W, Wang F, Huang Q, et al. MFB-CBRNN: a hybrid network for MI detection using 12-lead ECGs[J]. *IEEE J Biomed Health Inform*, 2020, 24(2): 503-514.
- [19] Siontis KC, Yao X, Pirruccello JP, et al. How will machine learning inform the clinical care of atrial fibrillation?[J]. *Circ Res*, 2020, 127(1): 155-169.
- [20] Belo D, Bento N, Silva H, et al. ECG biometrics using deep learning and relative score threshold classification[J]. *Sensors (Basel)*, 2020, 20(15): 4078.
- [21] Zhao Z, Liu C, Li Y, et al. Noise rejection for wearable ECGs using modified frequency slice wavelet transform and convolutional neural networks[J]. *IEEE Access*, 2019, 7(1): 34060-34067.
- [22] Zhao L, Liu C, Wei S, et al. Enhancing detection accuracy for clinical heart failure utilizing pulse transit time variability and machine learning[J]. *IEEE Access*, 2019, 7(1): 17716-17724.
- [23] Huang J, Chen B, Yao B, et al. ECG arrhythmia classification using STFT-based spectrogram and convolutional neural network[J]. *IEEE Access*, 2019, 7(1): 92871-92880.
- [24] Wotk K, Wolk A. Early and remote detection of possible heartbeat problems with convolutional neural networks and multipart interactive training[J]. *IEEE Access*, 2019, 7(1): 145921-145927.
- [25] Yıldırım Ö, Pławiak P, Tan RS, et al. Arrhythmia detection using deep convolutional neural network with long duration ECG signals[J]. *Comput Biol Med*, 2018, 102: 411-420.
- [26] Wang P, Hou B, Shao S, et al. ECG arrhythmias detection using auxiliary classifier generative adversarial network and residual network[J]. *IEEE Access*, 2019, 7(99): 100910-100922.
- [27] Poldervaart JM, Langedijk M, Backus BE, et al. Comparison of the GRACE, HEART and TIMI score to predict major adverse cardiac events in chest pain patients at the emergency department[J]. *Int J Cardiol*, 2017, 227: 656-661.

- 2019, 139(10):e56-e528.
- [4] Kim YH, Her AY, Rha SW, et al. Five-year major clinical outcomes between first-generation and second-generation drug-eluting stents in acute myocardial infarction patients underwent percutaneous coronary intervention[J]. *J Geriatr Cardiol*, 2018, 15(8):523-533.
 - [5] Holter NJ, Generelli JA. Remote recording of physiological data by radio[J]. *Rocky Mt Med J*, 1949, 46(9):747-751.
 - [6] Yetisen AK, Martinez-Hurtado JL, Ünal B, et al. Wearables in medicine[J]. *Adv Mater*, 2018, 30(33):e1706910.
 - [7] Allen J. Photoplethysmography and its application in clinical physiological measurement[J]. *Physiol Meas*, 2007, 28(3):R1-R39.
 - [8] Tison GH, Sanchez JM, Ballinger B, et al. Passive detection of atrial fibrillation using a commercially available smartwatch[J]. *JAMA Cardiol*, 2018, 3(5):409-416.
 - [9] Bashar SK, Han D, Hajeb-Mohammadipour S, et al. Atrial fibrillation detection from wrist photoplethysmography signals using smartwatches[J]. *Sci Rep*, 2019, 9(1):15054.
 - [10] Oehler M, Schilling M, Esperer HD. Capacitive ECG system with direct access to standard leads and body surface potential mapping[J]. *Biomed Tech (Berl)*, 2009, 54(6):329-335.
 - [11] Wiklund U, Karlsson M, Ostlund N, et al. Adaptive spatio-temporal filtering of disturbed ECGs: a multi-channel approach to heartbeat detection in smart clothing[J]. *Med Biol Eng Comput*, 2007, 45(6):515-523.
 - [12] Hedén B, Ohlin H, Rittner R, et al. Acute myocardial infarction detected in the 12-lead ECG by artificial neural networks[J]. *Circulation*, 1997, 96(6):1798-1802.
 - [13] Goto S, Kimura M, Katsumata Y, et al. Artificial intelligence to predict needs for urgent revascularization from 12-leads electrocardiography in emergency patients[J]. *PLoS One*, 2019, 14(1):e0210103.
 - [14] Sejersten M, Sillesen M, Hansen PR, et al. Effect on treatment delay of prehospital teletransmission of 12-lead electrocardiogram to a cardiologist for immediate triage and direct referral of patients with ST-segment elevation acute myocardial infarction to primary percutaneous coronary intervention[J]. *Am J Cardiol*, 2008, 101(7):941-946.
 - [15] Otto CM. Heartbeat: telemedicine and outcomes in patients with an acute coronary syndrome[J]. *Heart*, 2019, 105(19):1447-1449.
 - [16] Brunetti ND, de Gennaro L, Dellegrottaglie G, et al. Prevalence of cardiac arrhythmias in pre-hospital tele-cardiology electrocardiograms of emergency medical service patients referred for syncope[J]. *J Electrocardiol*, 2012, 45(6):727-732.
 - [17] Varma N, Epstein AE, Irimpen A, et al. Efficacy and safety of automatic remote monitoring for implantable cardioverter-defibrillator follow-up: the Lumos-T Safely Reduces Routine Office Device Follow-up (TRUST) trial[J]. *Circulation*, 2010, 122(4):325-332.
 - [18] Bravata DM, Smith-Spangler C, Sundaram V, et al. Using pedometers to increase physical activity and improve health: a systematic review[J]. *JAMA*, 2007, 298(19):2296-2304.
 - [19] Cook DJ, Thompson JE, Prinsen SK, et al. Functional recovery in the elderly after major surgery: assessment of mobility recovery using wireless technology[J]. *Ann Thorac Surg*, 2013, 96(3):1057-1061.
 - [20] Amir O, Azzam ZS, Gaspar T, et al. Validation of remote dielectric sensing (ReDS™) technology for quantification of lung fluid status: comparison to high resolution chest computed tomography in patients with and without acute heart failure[J]. *Int J Cardiol*, 2016, 221:841-846.
 - [21] Ng KG, Ting CM, Yeo JH, et al. Progress on the development of the MediWatch ambulatory blood pressure monitor and related devices[J]. *Blood Press Monit*, 2004, 9(3):149-165.
 - [22] Greco L, Percannella G, Ritrovato P, et al. Trends in IoT based solutions for health care: moving AI to the edge[J]. *Pattern Recognit Lett*, 2020, 135:346-353.
 - [23] Suciu G, Suciu V, Martian A, et al. Big data, internet of things and cloud convergence—An architecture for secure E-health applications[J]. *J Med Syst*, 2015, 39(11):141.
 - [24] Yahyaie M, Tarokh MJ, Mahmoodiyar MA. Use of internet of things to provide a new model for remote heart attack prediction[J]. *Telemed J E Health*, 2019, 25(6):499-510.
 - [25] Iqbal U, Wah TY, Habib Ur Rehman M, et al. Deep deterministic learning for pattern recognition of different cardiac diseases through the internet of medical things[J]. *J Med Syst*, 2018, 42(12):252.
 - [26] Rathore MM, Ahmad A, Paul A, et al. Real-time medical emergency response system: exploiting IoT and big data for public health[J]. *J Med Syst*, 2016, 40(12):283.

收稿日期:2020-09-02

(上接第 491 页)

- [28] Kwon J, Jeon K, Kim HM, et al. Deep-learning-based risk stratification for mortality of patients with acute myocardial infarction[J]. *PLoS One*, 2019, 14(10):e0224502.
- [29] Huo D, Kou B, Zhou Z, et al. A machine learning model to classify aortic dissection patients in the early diagnosis phase[J]. *Sci Rep*, 2019, 9(1):1-8.
- [30] Santos-Ferreira C, Baptista R, Oliveira-Santos M, et al. A 10- and 15-year performance analysis of ESC/EAS and ACC/AHA cardiovascular risk scores in a Southern European cohort[J]. *BMC Cardiovasc Disord*, 2020, 20(1):301.
- [31] Wu CC, Hsu WD, Islam MM, et al. An artificial intelligence approach to early predict non-ST-elevation myocardial infarction patients with chest pain[J]. *Comput Methods Programs Biomed*, 2019, 173:109-117.
- [32] Kwon JM, Kim KH, Jeon KH, et al. Artificial intelligence algorithm for predicting mortality of patients with acute heart failure[J]. *PLoS One*, 2019, 14(7):e0219302.
- [33] Zack CJ, Senecal C, Kinar Y, et al. Leveraging machine learning techniques to forecast patient prognosis after percutaneous coronary intervention[J]. *JACC Cardiovasc Interv*, 2019, 12(14):1304-1311.
- [34] Commandeur F, Slomka PJ, Goeller M, et al. Machine learning to predict the long-term risk of myocardial infarction and cardiac death based on clinical risk, coronary calcium, and epicardial adipose tissue: a prospective study[J]. *Cardiovasc Res*, 2020, 116(14):2216-2225.
- [35] Novak R, Xiao L, Hron J, et al. Neural tangents: fast and easy infinite neural networks in python [C]. Seattle: International conference on learning representations, arXiv, 2020.

收稿日期:2020-08-25