

基于卷积神经网络和长短时记忆网络的心肌梗死检测

刘建华, 吕建峰, 蔡金丹

三峡大学附属仁和医院心血管内科, 湖北 宜昌 443000

【摘要】为了进一步提升心肌梗死的诊断效果,提出一种基于卷积神经网络和长短时记忆网络的心肌梗死检测方法,用于准确地从心电图信号中检测心肌梗死。具体来讲,提出3种分别基于卷积神经网络、卷积神经网络结合长短时记忆网络以及它们的集成模型的检测方法,以期从心电信号中检测心肌梗死和正常搏动。此外,采用数据重采样方法,即合成少数类过采样方法和Tomek Link解决数据集不平衡问题。最终与其他方法的实验结果相比,经过数据重采样的集成卷积神经网络模型的结果取得了明显优势,证明提出方法的有效性。

【关键词】心肌梗死;心电图;卷积神经网络;长短时记忆网络

【中图分类号】R318

【文献标志码】A

【文章编号】1005-202X(2022)11-1448-05

Screening for myocardial infarction using convolutional neural network and long short-term memory network

LIU Jianhua, LÜ Jianfeng, CAI Jindan

Department of Cardiovascular Medicine, Renhe Hospital Affiliated to China Three Gorges University, Yichang 443000, China

Abstract: A screening method for myocardial infarction based on convolutional neural network and long short-term memory network is proposed to accurately detect myocardial infarction from electrocardiogram (ECG) signals, thereby further improving the diagnostic efficacy of myocardial infarction. Based on convolutional neural network, convolution neural network combined with long short-term memory network, and their integration, 3 different models are put forward to detect myocardial infarction and normal beats from ECG signals. In addition, the data resampling methods, namely synthetic minority oversampling technique and Tomek Link, are used to solve the class imbalance problem of data sets. The data resampled integrated convolutional neural network has obtained better experimental results than other methods, which proves the effectiveness of the proposed method.

Keywords: myocardial infarction; electrocardiogram; convolutional neural network; long short-term memory network

前言

心肌梗死是最常见且相当致命的心血管疾病。由于进入心肌的氧合血是由冠状动脉供应的,如果冠状动脉有任何阻塞,受累心肌段可能会因为没有血流入而死亡;而心肌组织的损伤或死亡会引起正常心脏传导系统的改变,从而导致危及生命的心律失常,进而导致心脏骤停^[1]。心肌梗死有时候可能会出现一些诸如突然发作剧烈而持久的胸骨后或心前

区压榨性疼痛、意识障碍、胃肠道症状、低血压或者休克等,但部分心肌梗死患者没有任何症状,这就是为什么它也被称为“无声心脏病”。这样一来,患者根本没有时间做好准备,也使得心肌梗死更加危险与致命,从而导致死亡率非常高^[2]。综上,心肌梗死的早发现对于其及时治疗与进一步降低死亡率非常重要。对于心电图的信号分析是早期提示心肌梗死较为常用的技术。但人工检测引起的误差或者出错可能引起严重的后果,甚至威胁患者的生命。本研究的主要目标是通过自动而准确地检测心电信号辅助医生对心肌梗死患者的诊断。

近年来,机器学习在包括医疗在内的各个计算机辅助领域都得到了极大程度的应用和发展^[3],其中尤为突出的是深度学习模型呈指数级增长的趋

【收稿日期】2022-05-13

【基金项目】湖北省卫生健康科研项目(WJ2021F061)

【作者简介】刘建华,主治医师,研究方向:心血管疾病诊治,E-mail: 35802648@qq.com

势^[4-5]。对于心肌梗死问题,一些研究人员利用支持向量机^[7]、决策树^[8]、k近邻^[9]、径向基函数^[10]和混合分类器^[11]以进行心电波形的分类而检测心肌梗死问题。在深度学习方法中,文献[12]提出了一种使用基于起始帧的浅层卷积神经网络以自动检测心肌梗死的方法,平均分类准确率达到83.48%。文献[13]提出了一种利用卷积神经网络对多导联心电信号进行心肌梗死检测的算法,他们提出的模型使用了可以利用全部导联的完整特性的二维卷积,同时也使用了一维滤波器以生成局部最优特征,最后在PTB(宾夕法尼亚树库, Penn Tree Bank)诊断心电数据集上对该算法进行了评价,其灵敏度为94.60%,特异度为96.25%,准确率为95.90%。文献[14]提出了一种利用时间-频率依赖性特征分布和加权最近邻方法对ST段进行分类,以从多导联心电波形中检测出心肌梗死,得到的平均灵敏度为94.61%,准确度为94.23%,特异度为98.18%。文献[15]提出了一种基于混合循环神经网络的方法预测12导联心电图的心肌梗死,总体准确率为92.07%。尽管如上所述提出了很多方法,但是对于基于心电信号的心肌梗死检测问题来说,仍有很大的改进空间。数据不平衡是医学信号和计算机视觉中最常见的问题,目前还没有改善这一问题的方法。本研究的主要方法为卷积神经网络加长短时记忆网络,而为了解决数据集不平衡问题,采用合成少数类过采样和Tomek Link方法,最后在PTB数据集中进行心肌梗死的检测。

1 相关技术及本研究方法

1.1 卷积神经网络

卷积神经网络最初是为计算机视觉领域的模式识别任务而设计的,用于边缘检测、分割和目标检测等任务,但由于其广泛的适用性,它几乎被用于所有的模式识别任务。卷积神经网络中常用的层有卷积层、线性整流单元层、池化层和批处理归一化层等。卷积层是卷积神经网络的第一层,进行卷积操作,由滤波器大小、滤波器数量和零填充组成。线性整流单元进行非线性运算,它是一种将非线性映射引入人工神经网络的激活函数。池化层中主要有两种类型的池化操作:最大池化和平均池化,它可以减少训练中的参数数量,避免陷入过拟合问题,进而提高网络效率。在训练过程中,批处理归一化通过应用当前批量的方差和均值对每一层的输入进行归一化处理。

1.2 长短时记忆网络

长短时记忆网络是目前被广泛应用于时间序列数据的深度学习模型,因为是短时记忆网络的改进

版本,因此叫做“长”短时记忆网络。长短时记忆网络中的基本概念是“门”和“单元”状态,分别为“遗忘门”、“输入门”、“单元状态”、“输出门”和“隐藏状态”^[16]。在遗忘门系统 f_t 中,当前输入 x_t 与之前的隐藏状态 h_{t-1} 进行连接,并通过sigmoid激活函数而产生0到1之间的输出,上述遗忘门的结构可以表达为:

$$f_t = \sigma(w_f[h_{t-1}, x_t] + b_f) \quad (1)$$

输入门(i_t)主要用于更新记忆或单元状态,在此门中还使用了sigmoid函数将当前输入值(x_t)和前一个隐藏状态(h_{t-1})进行串联,用下列方程表示:

$$i_t = \sigma(w_i[h_{t-1}, x_t] + b_i) \quad (2)$$

单元状态(C_t)也称为内存状态,该状态下的操作可分3个步骤进行。第一步,前一个单元状态(C_{t-1})与遗忘门(f_t)点乘(式1);第二步,候选向量(C_t)点乘以输入门(i_t)向量(式2);最后一步,这两个值加在一起创建存储单元即当前状态值(C_t),见下式:

$$C_t = f_t * C_{t-1} + i_t * \hat{C}_t \quad (3)$$

其中, $\hat{C}_t = \tanh(w_c[h_{t-1}, x_t] + b_c)$

输出门(O_t)也以类似于输入门和遗忘门的方式进行计算,同时权值和偏置值也不同,类似地,也使用sigmoid激活函数进行0到1之间的输出映射,即:

$$O_t = \sigma(w_o[h_{t-1}, x_t] + b_o) \quad (4)$$

隐藏状态(h_t)和单元状态记忆只传递到下一个长短时记忆网络的阶段,所有的门都用来调节和计算这些状态的值。它是输出门的值(式4)与双曲正切函数激活后的单元状态值和细胞状态值(式3)的向量点乘,即:

$$h_t = O_t * \tanh C_t \quad (5)$$

1.3 数据不平衡

如果两个类在样本容量上的差异很大,则称为数据不平衡。在数据不平衡的情况下,一个类(即多数类)比其他类具有更多的优势或对最终结果的影响更大^[17]。因为一般的分类器主要是为平衡类问题设计的,因此,不平衡数据集对分类器的性能影响相当严重。另一个问题是,这种不平衡数据可能无法在分类的总体准确性结果中显示出来,因为还需要使用不同的评价指标进一步验证性能。许多研究人员提出各种方法解决数据不平衡的问题。本研究联合使用合成少数类过采样方法和Tomek Link对数据集进行过采样和欠采样。对少数类数据进行过采样的方法是合成少数类过采样技术,它基于最近邻算法生成少数数据样本,从少数数据样本中选择最近邻,然后基于线性插值以生成新的样本^[18]。Tomek Link是在边界数据样本的基础上减少多数类实例数量的欠采样技术。此过程不断重复,通过删除多数类样本,造成多数类和少数类的边界之间的差距^[19]。

1.4 基于卷积神经网络和长短时记忆网络的心肌梗死检测方法

本节介绍利用不同的深度学习模型,即卷积神经网络、卷积神经网络结合长短时记忆网络和它们的集成模型以从心电信号中预测心肌梗死的方法。此外,为了解决数据不平衡问题,还采用了过采样方法。首先对心电信号进行过滤和分割的预处理,然后计算时间序列数据的时间间隔和梯度。下一步,利用卷积神经网络模型和卷积神经网络结合长短时记忆网络模型直接对预处理后的失衡数据进行训练。最后,使用合成少数类过采样和 Tomek Link 方法对不平衡数据集进行平衡,然后使用卷积神经网络模型和卷积神经网络结合长短时记忆网络模型进行训练。对两种模型的预测结果进行平均,如此可得到最终的集成模型性能。采用合成少数类过采样和 Tomek Link 的数据过采样代替数据增强技术,对少数类可以产生更多的样本。由于心电信号是时间序列的非线性数据,因此在众多的深度学习模型中,选择采用将卷积神经网络和长短时记忆网络相结合的集成方法。

1.4.1 数据集、评价指标和实验设置 本研究采用 PTB 数据集^[20]对心肌梗死进行检测,该数据集包括来自 290 人的 54 912 份导联心电图记录。其中 368 份记录中的 148 人被诊断为心肌梗死,80 份记录中的 52 人为健康对照组,其他记录被诊断为 7 种不同类型的心律失常。本研究使用两类的二导联心电图,即心肌梗死和健康的心电搏动,前者数量为 10 506,后者数量为 4 046。换句话说,心肌梗死的数据占比是 72%,正常数据占比为 28%。心电信号被分割并下采样,进行零填充以使所有的心电图大小相同,同时对所有的信号进行过滤和预处理。在使用分类器的预测任务中,数据分布也起着非常重要的作用。本研究中从 PTB 数据集中选取的心肌梗死和健康对照的 14 552 个心电搏动数据中,训练和测试数据集的分布比约为 80:20,即训练集 11 641 个,测试集 2 911 个。进一步,将训练数据集以 80:20 的比例分为用于学习的训练集和验证集两部分,即利用 9 312 次心电搏动对所提出的模型进行学习,并利用 2 329 次心电搏动对训练性能进行验证。

此外,为了估计分类器的性能,使用混淆矩阵并计算了 6 种性能评价指标,包括召回率、特异度、精准度、准确率、F1 分数和误分率,来验证模型分类结果。

$$\text{召回率} = \text{TP} / (\text{TP} + \text{FN}) \times 100\% \quad (6)$$

$$\text{特异度} = \text{TN} / (\text{TN} + \text{FP}) \times 100\% \quad (7)$$

$$\text{精准度} = \text{TP} / (\text{TP} + \text{FP}) \times 100\% \quad (8)$$

$$\text{准确率} = (\text{TP} + \text{TN}) / (\text{TP} + \text{TN} + \text{FP} + \text{FN}) \times 100\% \quad (9)$$

$$\text{F1 分数} = 2 \times \text{精准度} \times \text{召回率} / (\text{精准度} + \text{召回率}) \times 100\% \quad (10)$$

$$\text{误分率} = (\text{FP} + \text{FN}) / (\text{TP} + \text{TN} + \text{FP} + \text{FN}) \times 100\% \quad (11)$$

其中,TP 为正阳性,TN 为正阴性,FP 为负阳性,FN 为负阴性。

本研究使用 Python 编程语言,TensorFlow 深度学习框架和 keras 库在 GPU 的支持下对模型进行训练和评估。实验使用 8 GB 内存、1 TB 硬盘、i5 内核奔腾处理器和 NVIDIA 显卡的笔记本电脑。训练过程中使用的优化器为 Adam 优化器,批量大小为 128,动量值为 0.9,学习率为 0.001,epoch 为 100,权重衰减系数为 0.000 1。

1.4.2 卷积神经网络模型 为了准确地从心电信号中检测出心肌梗死,提出一个 21 层的卷积神经网络模型^[22]。输入是样本大小为 87×1 的一维心电信号,将其重构为 187×2×1 使其适合于二维卷积层。整个网络的架构可划分为 4 个阶段,前两个阶段包括卷积层,然后是批量归一化^[23]、线性整流非线性化^[24]、最大池化层以及 dropout 层^[25]。第 2 个阶段重复数量为 128 个的卷积核以提取深度特征,第 3 和第 4 阶段去掉了最大池化层以保持特征图的尺寸。在整个模型中卷积操作的步长皆为 1。从第 1 阶段到第 4 阶段的卷积核数分别为 256、128、64、64。

1.4.3 卷积神经网络结合长短时记忆网络模型 为了准确地从心电信号中检测出心肌梗死,还设计了 19 层的卷积神经网络结合长短时记忆网络混合模型。类似地,整个设计可分为 4 个阶段,前两个阶段与 1.4.2 节的卷积神经网络模型完全相同,但为了得到更好的结果,对第 3 和第 4 阶段进行优化:这两个阶段没有包含最大池化层,以避免特征图尺寸进一步减小,第 4 阶段由重塑层和长短时记忆网络层组成,然后再与原来的卷积神经网络模块结合。

2 实验结果及分析

第 1 个实验是在不平衡数据集上使用卷积神经网络、卷积神经网络结合长短时记忆网络和它们的集成模型进行的消融实验。对原始的不平衡数据集进行训练,训练后对测试数据集进行验证,各个模型的评价指标如表 1。从预测结果来看,两种模型的集合结果在各个指标上都优于单一模型,无论是卷积神经网络或是卷积神经网络结合长短时记忆网络模型。在失衡数据集上,利用卷积神经网络、卷积神经网络结合长短时记忆网络和集成模型获得的准确率分别为 99.3%、99.5% 和 99.6%。

第 2 个实验是在经过合成少数类过采样方法和 Tomek Link 采样方法的类平衡数据集上进行的。经过对数据的采样,两类样本总计 11 641 个的心电图搏动被过采样到 16 798 个,其中每类 8 399 个。因此,在

表 1 提出的方法在原始不平衡数据集中训练后得到的结果(%)

Table 1 Results of the proposed method after training in the original unbalanced data set (%)

模型	精准度	召回率	特异度	F1 分数	误分率	准确率
卷积神经网络	99.4	99.4	98.9	99.1	70	99.3
卷积神经网络结合长短时记忆网络	99.6	99.6	99.2	99.4	50	99.5
集成模型	99.6	99.6	99.4	99.5	40	99.6

平衡数据集后,再使用深度学习模型进行训练,而测试其实是在原本失衡的数据集上进行。表 2 的预测结果表明,与不平衡数据集相比,每类的精度皆有所提高,总体精度也有所提高。在平衡数据集上,利用卷积神经网络、卷积神经网络结合长短时记忆网络和集成模型获得的准确率分别为 99.5%、99.7% 和 99.8%。因此,通过使用合成少数类过采样方法和 Tomek Link 采样方法平衡数据集,不仅整体精度提高,而且每个类的预测值也提高了。此外,在表 3 中比较了本文方法与其他方法的性能,这也进一步验证所提出的模型的有效性。

表 2 提出的方法在经过采样出来的平衡数据集中训练后得到的结果(%)

Table 2 Results of the proposed method after training in the sampled balanced data set (%)

模型	精准度	召回率	特异度	F1 分数	误分率	准确率
卷积神经网络	99.5	99.5	99.3	99.4	50	99.5
卷积神经网络结合长短时记忆网络	99.6	99.6	99.5	99.6	30	99.7
集成模型	99.8	99.8	99.8	99.8	20	99.8

表 3 与其他方法的结果对比

Table 3 Comparison with other methods

方法	数据集	准确率/%
文献[21]	PTB	96.7
文献[12]	PTB	96.2
文献[13]	PTB	96.7
文献[7]	PTB	94.8
文献[2]	PTB	97.7
文献[15]	PTB	94.4
文献[10]	PTB	97.3
文献[14]	EDB, MIT LST	94.2
集成模型	PTB	99.8

3 小 结

本研究提出了一种将卷积神经网络和长短期记

忆网络进行集成的深度学习模型,以此利用心电图数据集对心肌梗死进行自动而准确的预测。为了解决类不平衡问题,采用合成少数过采样技术和 Tomek Link 数据采样技术平衡数据。该模型直接以 PTB 数据集中的心电跳动时间间隔及其梯度值作为特征进行输入,与其他方法结果的对比证明了本研究提出的集成模型的有效性。

【参考文献】

[1] 黄伟红. 不同心电图检查在诊断冠心病心律失常中的应用对比[J]. 哈尔滨医药, 2021, 41(6): 96-97.
Huang WH. Comparison of different ECG examination in diagnosis of arrhythmia in coronary heart disease[J]. Harbin Medical Journal, 2021, 41(6): 96-97.

[2] 朱涛, 张国明, 严飞, 等. 急性心肌梗死患者 PCI 术后心率变异性对主要不良心脏事件的评估价值[J]. 吉林大学学报(医学版), 2018, 44(4): 780-785.
Zhu T, Zhang GM, Yan F, et al. Values of evaluation of heart rate variability in major adverse cardiac events in patients with acute myocardial infarction after PCI [J]. Journal of Jilin University (Medicine Edition), 2018, 44(4): 780-785.

[3] 卢婷婷, 卢英华. 优化急诊流程对急诊 ST 段抬高型心肌梗死溶栓治疗患者急救时间及救治成功率的影响[J]. 基层医学论坛, 2021, 25(36): 5311-5313.
Lu TT, Lu YH. Effect of emergency procedure optimization on emergency time and success rate of thrombolytic therapy for ST-segment elevation myocardial infarction [J]. The Medical Forum, 2021, 25(36): 5311-5313.

[4] 吴行伟, 刘馨宇, 龙恩武, 等. 机器学习在临床药物治疗中的研究进展[J]. 中国全科医学, 2022, 25(2): 254-258.
Wu XW, Liu XY, Long EW, et al. Research progress of machine learning in clinical drug therapy[J]. Chinese General Practice, 2022, 25(2): 254-258.

[5] 刘利梅, 陈晓晋, 孙世伟, 等. 深度学习应用于药物活性预测研究综述[J]. 生物化学与生物物理进展, 2022, 49(8): 1498-1519.
Liu LM, Chen XJ, Sun SW, et al. A review of deep learning application on drug activity prediction [J]. Progress in Biochemistry and Biophysics, 2022, 49(8): 1498-1519.

[6] 杨鸿杰, 徐巧枝, 于磊. 基于深度学习的多模态医学影像分割研究综述[J]. 计算机应用研究, 2022, 39(5): 1297-1306.
Yang HJ, Xu QZ, Yu L. Multi-mode medical image segmentation based on deep learning: a review [J]. Application Research of Computers, 2022, 39(5): 1297-1306.

[7] Ramanathan N, Chellappa R, Biswas S. Age progression in human faces: a survey[J]. J Visual Lang Comput, 2009, 15(7): 14-19.

[8] Khalaf AF, Owis MI, Yassine IA. A novel technique for cardiac arrhythmia classification using spectral correlation and support vector machines[J]. Expert Syst Appl, 2015, 42(21): 8361-8368.

[9] Alarsan FI, Younes M. Analysis and classification of heart diseases using heartbeat features and machine learning algorithms[J]. J Big Data, 2019, 6(1): 357-368.

[10] Savostin AA, Ritter DV, Savostina GV. Using the K-nearest neighbors algorithm for automated detection of myocardial infarction by electrocardiogram data entries[J]. Pattern Recogn Image Anal, 2019, 29(4): 730-737.

[11] Singh R, Mehta R, Rajpal N. Efficient wavelet families for ECG classification using neural classifiers[J]. Procedia Comput Sci, 2018, 132(4): 11-21.

[12] Hmb C, Hfa B, Eh C, et al. Recognition of ECG signals using wavelet based on atomic functions-ScienceDirect[J]. Biocybern Biomed Eng, 2020, 40(2): 803-814.

[13] Baloglu UB, Talo M, Yildirim O, et al. Classification of myocardial infarction with multi-lead ECG signals and deep CNN[J]. Pattern Recogn Lett, 2019, 122: 23-30.

[14] Liu WH, Zhang MX, Yuan YD, et al. Real-time multilead convolutional neural network for myocardial infarction detection [J]. IEEE J Biomed Health Inform, 2017, 3(2): 108-123.

- [15] Garland J, Hu M, Duffy M, et al. Classifying microscopic acute and old myocardial infarction using convolutional neural networks[J]. Am J Forensic Med Pathol, 2021, 42(3): 230-234.
- [16] Prabhakararao E, Dandapat S. Attentive RNN-based network to fuse 12-lead ECG and clinical features for improved myocardial infarction diagnosis[J]. IEEE Signal Process Lett, 2020, 27: 2029-2033.
- [17] Graves A, Schmidhuber J. Framewise phoneme classification with bidirectional LSTM and other neural network architectures[J]. Neural Networks, 2005, 18(5-6): 602-610.
- [18] 周玉, 孙红玉, 房倩, 等. 不平衡数据集分类方法研究综述[J]. 计算机应用研究, 2022, 39(6): 1615-1621.
- Zhou Y, Sun HY, Fang Q, et al. A review on classification methods of unbalanced data sets[J]. Application Research of Computers, 2022, 39(6): 1615-1621.
- [19] Chawla NV, Bowyer KW, Hall LO, et al. SMOTE: synthetic minority over-sampling technique[J]. J Artif Intell Res, 2011, 21(3): 321-357.
- [20] Arbelaitz O, Gurrutxaga I, Muguerza J, et al. Applying resampling methods for imbalanced datasets to not so imbalanced datasets[C]// Conference of the Spanish Association for Artificial Intelligence. Berlin: Springer, 2013: 9-17.
- [21] Li W, Tang YM, Yu KM, et al. SLC-GAN: an automated myocardial infarction detection model based on generative adversarial networks and convolutional neural networks with single-lead electrocardiogram synthesis[J]. Inform Sci, 2022, 589: 738-750.
- [21] Kora P. ECG based myocardial infarction detection using hybrid firefly algorithm [J]. Comput Methods Programs Biomed, 2017, 152: 141-148.
- [22] Chen Z, Cen J, Xiong J. Rolling bearing fault diagnosis using time-frequency analysis and deep transfer convolutional neural network[J]. IEEE Access, 2020, 99: 1-12.
- [23] Hamil H, Zidelmal Z, Azzaz MS, et al. AF episodes recognition using optimized time-frequency features and cost-sensitive SVM[J]. Phys Eng Sci Med, 2021, 44(3): 613-624.
- [24] Pal P, Ghosh S, Chattopadhyay BP, et al. Screening of ischemic heart disease based on PPG signals using machine learning techniques[C]// Annu Int Conf IEEE Eng Med Biol Soc. 2020: 5980-5983.
- [25] Agliari E, Barra A, Barra OA, et al. Detecting cardiac pathologies via machine learning on heart-rate variability time series and related markers[J]. Sci Rep, 2020, 10(1): 8845-8937.

(编辑:黄开颜)