

文章编号: 2095-2163(2024)03-0081-05

中图分类号: TP391.4

文献标志码: A

基于最小门控单元的心音分类研究

王慧

(贵阳信息科技学院 智能工程系, 贵阳 550025)

摘要: 本文提出了一种基于最小门控单元(minimal gated unit, MGU)网络的心音分类方法, 为心血管疾病的诊断提供了一种无创、便捷的新方法。首先, 对采集到的心音信号进行自适应小波去噪预处理后, 利用基于逻辑回归的隐半马尔可夫模型对心音信号进行分割, 并搭建 MGU 模型, 本文研发模型能够自动学习心音信号的特征。实验结果表明, 该模型的准确率达到了97.20%, 取得了较好的效果, 可作为心血管疾病诊断的有效工具, 辅助临床诊断。

关键词: 心血管疾病; 心音; 最小门控单元; 深度学习

Classification of heart sounds based on minimal gated unit

WANG Hui

(Department of Intelligent Engineering, Guiyang Institute of Information Science and Technology, Guiyang 550025, China)

Abstract: The classification method of heart sounds based on minimal gated unit (MGU) network is proposed in this paper, which provides a new noninvasive and convenient method for the diagnosis of cardiovascular diseases. Firstly, the collected heart sound signals are preprocessed by adaptive wavelet denoising. Then, the logistic regression based hidden semi-Markov model is utilized to segment HS frames. After that, the MGU model is built for the classification of heart sounds, which can automatically learn the features of heart sound signals. The results show that the proposed model achieves the superior performance with the accuracy of 97.20%. This study suggests the proposed method could be a useful tool for the diagnosis of cardiovascular diseases and assisting physicians in clinical diagnosis.

Key words: cardiovascular diseases; heart sounds; minimal gated unit; deep learning

0 引言

随着社会经济的发展及人口老龄化过程的进一步加剧, 心血管疾病的患病率处于持续上升趋势, 国内的心血管疾病防治工作面临严峻挑战^[1]。据世界卫生组织统计, 心血管疾病是全球最主要的致死因素之一, 约占全球总死亡人数的三分之一。因此, 探索和改进行心音信号的分析和处理, 弥补缺乏了传统心音听诊的缺陷。利用计算机辅助诊断技术进

行心音信号的分析, 可以获得量化的特征参数, 有助于发现心音与相关疾病之间的关系, 也有利于后续数据的可追溯性及数据库的形成^[3]。

传统的机器学习方法需要对心音信号进行复杂的预处理、手动提取和选择特征, 增加了一定的工作量。此外, 由于机器学习方法所用的数据量较小, 其泛化能力和鲁棒性无法得到保证。随着人工智能算法的快速发展, 深度学习模型被应用于心音分类。其中, 循环神经网络 (Recurrent Neural Network, RNN) 和卷积神经网络 (Convolutional Neural Network, CNN) 等深度学习模型应用最为广泛。李嘉琪等学者^[4]利用短时傅里叶变换提取心音信号的时频图, 输入改进的 ResNet50 中进行心音自动分类。Wu 等学者^[5]提取了心音信号的短时傅里叶变换频谱图、梅尔频谱以及梅尔频率倒谱系数作为模型的输入矩阵, 并使用 CNN 模型中的 VGG 网络进行训练, 最终达到了 89.81% 的测试准确率。孟丽楠等学者^[6]提出采用大量未经过精确分割的心音二

作者简介: 王慧 (1997-), 女, 硕士, 助教, 主要研究方向: 医学信号检测与分析。Email: wanghui970810@163.com

收稿日期: 2024-01-07

哈尔滨工业大学主办 ◆ 系统开发与应用

维特征图作为深度 CNN 网络的输入,实现心音的分类识别。虽然 RNN 擅长处理时间序列,但存在着梯度消失或梯度爆炸的问题。针对于此,相继推出了一系列改进网络,如:长短时记忆网络(Long Short-Term Memory, LSTM)、门控循环单元(Gated Recurrent Unit, GRU)等^[7-8]陆续被提出。Lynn 等学者^[9]采用 GRU 网络识别心律失常,准确率为 98.55%。Latif 等学者^[10]提出了一种基于循环神经网络(RNN)的异常心跳检测算法,探索了 LSTM、GRU、双向 LSTM 和双向 GRU 四种模型的性能和计算复杂度。LSTM 和 GRU 解决了 RNN 中存在梯度消失或梯度爆炸的问题,但其网络结构中仍存在着大量复杂的隐藏单元。而最小门控单元(Minimal Gated Unit, MGU)^[11]具有最简单的门控设计,参数较少,精度与 GRU 相似。徐菲菲等学者^[12]结合 CNN 和 MGU 的优势搭建神经网络模型进行情感分类实验,结果表明模型能够学习序列相关特征,有效地提高情感分类的准确率。刘志明等学者^[13]基于 MGU 网络进行中文分词研究,与 LSTM 网络精度相当、且其标注推理速度更快。

目前,将 MGU 应用于心音分类的研究较少,因此本文提出一种新的 MGU 模型,以实现正常和异常心音的分类。为验证模型性能,将该模型与 LSTM、GRU 等模型进行了对比分析。

1 分类模型

1.1 长短时记忆网络

LSTM 网络由一系列循环连接的内存单元构成,包括输入门、遗忘门和输出门,其结构如图 1 所示。

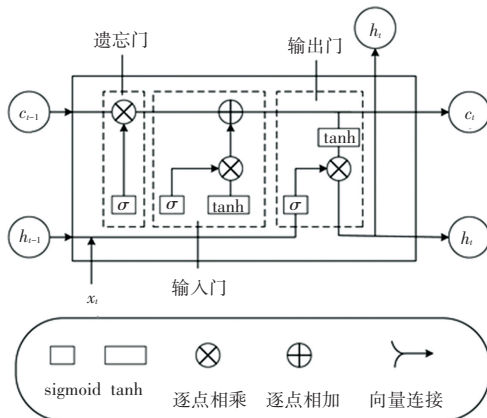


图1 LSTM 结构示意图

Fig. 1 Structure of LSTM

LSTM 的核心是一个记忆单元,其作用是记住有用的信息,而遗忘无用或者对结果影响较小的信息。计算过程如下:

$$f_t = \sigma(W_{f_h}h_{t-1} + W_{f_x}x_t + b_f) \quad (1)$$

$$i_t = \sigma(W_{i_h}h_{t-1} + W_{i_x}x_t + b_i) \quad (2)$$

$$\tilde{c}_t = \tanh(W_{\tilde{c}_h}h_{t-1} + W_{\tilde{c}_x}x_t + b_{\tilde{c}}) \quad (3)$$

$$c_t = f_t \cdot c_{t-1} + i_t \cdot \tilde{c}_t \quad (4)$$

$$o_t = \sigma(W_{o_h}h_{t-1} + W_{o_x}x_t + b_o) \quad (5)$$

$$h_t = o_t \cdot \tanh(c_t) \quad (6)$$

其中,遗忘门 f_t 控制对上一个状态的遗忘,忘记无用信息,留下有用信息;输入门 i_t 将新的信息记录到当前单元状态中;输出门 o_t 控制输出有关信息。

1.2 门控循环单元网络

GRU 是 LSTM 网络的一种效果很好的变体,结构更加简单,只有重置门、更新门,其结构如图 2 所示。




图2 GRU 结构示意图

Fig. 2 Structure of GRU

由于 GRU 参数的数量少于 LSTM,整体训练速度要快于 LSTM。计算过程如下:

$$r_t = \sigma(W_{r_h}h_{t-1} + W_{r_x}x_t + b_r) \quad (7)$$

$$z_t = \sigma(W_{z_h}h_{t-1} + W_{z_x}x_t + b_z) \quad (8)$$

$$\tilde{h}_t = \tanh(W_{\tilde{h}_h}(r_t \cdot h_{t-1}) + W_{\tilde{h}_x}x_t + b_{\tilde{h}}) \quad (9)$$

$$h_t = (1 - z_t) \cdot h_{t-1} + z_t \cdot \tilde{h}_t \quad (10)$$

其中,重置门 r_t 决定对过去状态的信息的遗忘程度;更新门 z_t 取代了 LSTM 中的输入门和遗忘门,决定遗忘或保留先前状态信息量和需要增加的当前状态信息量。

1.3 最小门控单元

LSTM 和 GRU 中依然存在着许多复杂的隐层单元,为了进一步简化结构,减少参数数量,Zhou 等学者^[11]于 2016 年提出了 MGU,结构如图 3 所示。MGU 是 RNN 中任意门控单元的最小设计,只有一个遗忘门,可以学习时间序列的长期时间相关性,而不受梯度消失或者梯度爆炸的影响。

MGU 是在 GRU 的基础上发展得来的,是将输入(重置)门进一步耦合到遗忘门(更新门):

$$r_t = f_t, \quad \forall t \quad (11)$$

其中, f_t 表示遗忘门,可视为 GRU 中更新门的重命名,计算公式如下所示。

$$f_t = \sigma(W_{fh}h_{t-1} + W_{fx}x_t + b_f) \quad (12)$$

在 W_{hh}^- 、 W_{hx}^- 和 b_h^- 权重下, $f_t \cdot h_{t-1}$ 与 x_t 连接成一个新的向量作为 \tanh 函数的输入,从而得到短时记忆项 \tilde{h}_t :

$$\tilde{h}_t = \tanh(W_{hh}^-(f_t \cdot h_{t-1}) + W_{hx}^-x_t + b_h^-) \quad (13)$$

新的隐层状态 h_t 由 2 部分组成,其中, $1 - f_t$ 和 h_{t-1} 之间的元素乘积为第一部分,由 f_t 再次确定的 \tilde{h}_t 组成 h_t 的第二部分。据此可推得:

$$h_t = (1 - f_t) \cdot h_{t-1} + f_t \cdot \tilde{h}_t \quad (14)$$




图3 MGU 结构示意图

Fig. 3 Structure of MGU

由 LSTM、GRU 和 MGU 的结构图和计算公式可发现, MGU 比 LSTM 和 GRU 更加简化。LSTM 由 4 组参数确定: f, i, \tilde{c}, o ; GRU 由 3 组参数确定: r, z, \tilde{h} ; 而 MGU 只有 2 组参数: f, \tilde{h} 。若隐层节点数相同,则可近似认为 MGU 的参数仅为 LSTM 的一半,是 GRU 的三分之二左右。

2 网络结构

2.1 MGU 模型

本文基于 MGU 网络构建心音分类模型,如图 4 所示。模型主要包括输入层、隐含层和输出层三个部分。

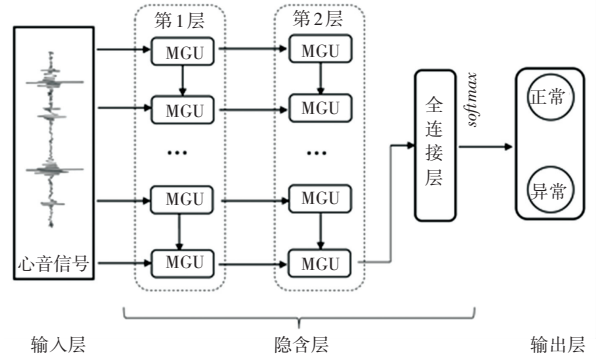


图4 MGU 模型示意图

Fig. 4 Illustration of MGU model

输入层向网络传送预处理后的心音数据。在隐含层中,需要确定隐含层层数和每层节点数,合适的隐含层层数以及每层节点数可提高网络的性能。一般认为,若隐含层层数过多,会使网络复杂化,增加了网络的训练时间,容易产生过拟合现象,且每层节点数的选取不当也会造成网络过拟合。本文中,采用实验方式确定隐含层层数以及每层节点数,将隐含层层数和每层节点数的范围分别设定为 $\{1, 2, 3\}$, $\{8, 16, 32, 64, 128\}$,以准确率为评价指标进行模型结构的测试。最终确定 MGU 模型的隐含层层数为 2,每层节点数为 64。输出层采用 softmax 函数完成分类,本文为二分类问题,因此输出层的节点数为 2。

此外,为验证模型性能,将该模型与 LSTM、GRU 等模型进行对比分析。即将图 4 中的 MGU 层依次替换成 LSTM 和 GRU。LSTM 和 GRU 模型的结构与 MGU 相同。

2.2 模型训练

本文选用 Adam 优化器优化模型参数,Adam 可计算参数的自适应学习率,加快网络的收敛速度。学习率设置为 0.001,损失函数为 L2 正则化的交叉熵损失函数,正则项系数设置为 0.001。此外,采用 dropout 技术防止模型在训练过程中出现过拟合现象,参数值设置为 0.5。综合考虑训练时间和模型性能两个因素,将训练次数设置为 50,批处理大小为 64。随着训练过程的进行, MGU 模型的性能不断提高,如图 5 所示。




图5 MGU模型训练过程中的准确率和损失值示意

Fig. 5 Accuracy and loss during the training of the MGU model

3 实验结果及分析

3.1 实验数据集划分及评价指标

本文使用的心音样本包含2类:正常心音和异常心音。样本来自于2016年心脏病学PhysioNet/Computing挑战赛^[14-15]。该数据集共包含3 240条记录,其中2 575份正常心音数据来自健康受试者,其余665份异常心音来自心血管疾病确诊患者。数据集信息见表1,其中包含6个心音数据集(a-f)。每条心音数据以2 kHz采样,并具有不同的持续时间(5~120 s)。

表1 PhysioNet/Computing挑战赛数据集信息

Table 1 Information of PhysioNet/Computing dataset

数据集	正常数	异常数
a	292	117
b	104	286
c	24	7
d	28	27
e	183	1 958
f	34	80

因为心音主要成分中频率范围最高的为 S_2 ,其值介于10~200 Hz之间,所以根据奈奎斯特采样定

理,将所有样本统一降采样至600 Hz。而为了削弱病理性幅值差异对结果产生影响,需对所有样本进行幅值归一化处理:

$$X = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (15)$$

本文使用的去噪方法为Liu等学者^[16]提出的自适应小波去噪,该方法已被证实为有效的去噪方法,可以实现不同的心音信号自适应选择不同的母小波和分解层数。使用基于逻辑回归的隐半马尔可夫模型^[17-19]定位基础心音 S_1 和 S_2 的边界(如图6所示)。以 S_1 为起始位置,固定心音片段长度为1.6 s,并以2个周期为间隔对心音进行截取^[20]。共得到心音样本4 000个,各类心音样本数量详见表2。




图6 定位 S_1 和 S_2 边界的示意图

Fig. 6 Illustration of locating the boundary of S_1 and S_2

表2 各类心音样本数量

Table 2 Information of heart sound samples

类型	样本数量	样本长度/s
正常	2 000	1.6
异常	2 000	1.6

本文实验采用十折交叉验证方法,每次训练时,90%数据作为训练集,10%数据作为测试集,且用于训练的80%数据划分为训练集,20%为验证集。训练集、验证集和测试集中不包含相同样本。选用准确率(Accuracy, Acc)、精准率(Precision, Pre)、召回率(Recall, Rec)和 $F1$ 值作为模型性能的评价指标。各指标定义如下:

$$Acc = \frac{TP + TN}{TP + TN + FN + FP} \times 100\% \quad (16)$$

$$Rec = \frac{TP}{TP + FN} \times 100\% \quad (17)$$

$$Pre = \frac{TP}{TP + FP} \times 100\% \quad (18)$$

$$F1 = \frac{2TP}{2TP + FP + FN} \times 100\% \quad (19)$$

其中, TP, TN, FP, FN 分别表示真阳性、真阴性、假阳性和假阴性。

3.2 结果分析

为验证本文模型的有效性,将本文模型与 LSTM、GRU 等模型进行对比,对比结果见表 3。

表 3 不同模型的性能对比结果

Table 3 Performance comparison results of different models

模型	Acc(±SD)	Pre(±SD)	Rec(±SD)	F1(±SD)	参数数量
LSTM	92.78(±1.74)	92.91(±1.81)	92.79(±1.85)	92.70(±1.84)	49 408
GRU	96.46(±0.65)	96.47(±0.70)	96.46(±0.61)	96.46(±0.80)	37 056
MGU	97.20(±0.34)	96.67(±0.33)	96.61(±0.34)	96.82(±0.35)	24 704

4 结束语

本文提出了一种新 MGU 模型,实现了正常心音和异常心音的分类,准确率达到 97.20%。通过与 LSTM、GRU 等模型进行对比实验, MGU 具有最小的门控单元设计和更少的参数,且其分类精度更高。表明该模型在心音的分类中是有效的,可以为临床上的心血管疾病诊断提供一种有效的辅助手段。由于本文的心音数据量较小,后期研究工作中可考虑扩大样本量,进一步改进模型的泛化能力和精度。

参考文献

[1] 胡盛寿,王增武.《中国心血管健康与疾病报告 2022》概述[J]. 中国心血管病研究, 2023, 21(7): 577-600.

[2] DELGADO-TREJOS E, QUICENO-MANRIQUE A F, GODINO-LLORENTE J I, et al. Digital auscultation analysis for heart murmur detection[J]. Annals of Biomedical Engineering, 2009, 37(2): 337-353.

[3] 侯爱生,兰琛,罗云根,等. 心音监测技术临床应用的研究进展[J]. 中华老年多器官疾病杂志, 2022, 21(12): 957-960.

[4] 李嘉琪,全星日. 基于改进 ResNet50 的心音分类算法研究[J]. 电脑知识与技术, 2022, 18(21): 76-78.

[5] WU J M T, TSAI M H, HUANG Yongzhi, et al. Applying an ensemble convolutional neural network with Savitzky-Golay filter to construct a phonocardiogram prediction model[J]. Applied Soft Computing, 2019, 78: 29-40.

[6] 孟丽楠,谢红薇,宁晨,等. 基于深度卷积神经网络的心音分类算法[J]. 2021, 29(8): 211-217.

[7] ELSAYED N, MAIDA A S, BAYOUMI M. Deep gated recurrent and convolutional network hybrid model for univariate time series classification[J]. International Journal of Advanced Computer Science and Applications, 2019, 10(5): 654-664.

[8] CHUNG J, GULCEHRE C, CHO K, et al. Empirical evaluation of gated recurrent neural networks on sequence modeling[J]. arXiv preprint arXiv:1412.3555, 2014.

[9] LYNN H M, PAN S B, KIM P. A deep bidirectional GRU

由表 3 可以看出,本文提出的 MGU 模型优于其他分类模型。MGU 的平均识别准确率为 97.20%,较 LSTM 和 GRU 分别提高 4.42% 和 0.74%,模型的性能也更加稳定。此外, MGU 模型的参数量少于其他模型,平均训练时间为 34.55 min,比 LSTM 和 GRU 分别快了 10.23 min 和 6.34 min。

network model for biometric electrocardiogram classification based on recurrent neural networks[J]. IEEE Access, 2019, 7: 145395-145405.

[10] LATIF S, USMAN M, RANA R, et al. Phonocardiographic sensing using deep learning for abnormal heartbeat detection[J]. IEEE Sensors Journal, 2018, 18(22): 9393-9400.

[11] ZHOU Guobing, WU Jianxin, ZHANG Chenlin, et al. Minimal gated unit for recurrent neural networks[J]. International Journal of Automation and Computing, 2016, 13(3): 226-234.

[12] 徐菲菲,芦霄鹏. 结合卷积神经网络和最小门控单元注意力的文本情感分析[J]. 计算机应用软件, 2020, 37(9): 75-80.

[13] 刘志明,孙严伟,欧阳纯萍,等. 基于最简门单元的循环神经网络分词[J]. 计算机工程与设计, 2019, 40(5): 1328-1333.

[14] CLIFFORD G, LIU Chengyu, SPRINGER D, et al. Classification of normal/abnormal heart sound recordings: The physioNet/computing in cardiology challenge 2016 [J]. Computing in Cardiology, 2016, 43: 609-612.

[15] LIU Chengyu, SPRINGER D, LI Qiao, et al. An open access database for the evaluation of heart sound algorithms [J]. Physiological Measurement, 2016, 37(12): 2181-2213.

[16] LIU Yongmin, GUO Xingming, ZHENG Yineng. An automatic approach using ELM classifier for HFpEF identification based on heart sound characteristics[J]. Journal of Medical Systems, 2019, 43(9): 285-293.

[17] SPRINGER D B, TARASSENKO L, CLIFFORD G D. Support vector machine hidden semi-markov model-based heart sound segmentation [C]//Computing in Cardiology 2014. Cambridge, USA: IEEE, 2014: 625-628.

[18] SPRINGER D, TARASSENKO L, CLIFFORD G. Logistic regression-HSMM-based heart sound segmentation [J]. IEEE Transactions on Biomedical Engineering, 2015, 63(4): 822-832.

[19] LIU Chengyu, SPRINGER D, CLIFFORD G D. Performance of an open-source heart sound segmentation algorithm on eight independent databases[J]. Physiological Measurement, 2017, 38(8): 1730-1745.

[20] GAO Shan, ZHENG Yineng, GUO Xingming. Gated recurrent unit-based heart sound analysis for heart failure screening [J]. BioMedical Engineering Online, BioMed Central, 2020, 19(1): 1-17.