

基于多模态特征工程和TSNet的 心脏异常检测算法

刘纪红¹, 薛维¹, 徐超²

(1. 东北大学 信息科学与工程学院, 辽宁 沈阳 110819; 2. 东北大学 计算机科学与工程学院, 辽宁 沈阳 110169)

摘要: 心电图(electrocardiogram, ECG)和心音图(phonocardiogram, PCG)是心脏疾病诊断中常用的图像, 单一的方法进行心脏疾病诊断效果不佳. 基于多模态特征工程, 数据集经过切分和归一化预处理后, 使用格拉姆角场(Gramian angle fields, GAF)进行时间序列数据重建, 形成图像模型. 提出一种适用于该图像模型的双流自融合网络(two-stream self-fusion network, TSNet), 使用双流自融合(two-stream self-fusion, TS)模块替代底层卷积操作, 更好地融合ECG和PCG的异构信息. 经Physio Net Challenge 2016 a数据集测试, 该算法的准确率、F1值、精确率和召回率最佳值分别达到95.3%, 95.4%, 96.2%, 99.4%, 相较于其他心电图和心音多模态卷积神经网络算法, 精度更高.

关键词: 心电图; 心音图; 多模态特征工程; 格拉姆角场; 双流自融合网络

中图分类号: TP 391.7 文献标志码: A 文章编号: 1005-3026(2024)10-1394-08

Heart Anomaly Detection Algorithm Based on Multimodal Feature Engineering and TSNet

LIU Ji-hong¹, XUE Wei¹, XU Chao²

(1. School of Information Science & Engineering, Northeastern University, Shenyang 110819, China; 2. School of Computer Science & Engineering, Northeastern University, Shenyang 110169, China. Corresponding author: LIU Ji-hong, E-mail: liujihong@ise.neu.edu.cn)

Abstract: Electrocardiogram (ECG) and Phonocardiogram (PCG) are commonly used diagrams in heart diseases diagnosis. While, using them alone for heart disease diagnosis is not effective. Based on multimodal feature engineering, after segmentation and normalization preprocess of the dataset, Gramian angle fields (GAF) are used for time-series data reconstruction to form an image model. Additionally, a two-stream self-fusion network (TSNet) suitable for this image model is proposed, which replaces the bottom-layer convolution operations with a two-stream self-fusion (TS) module to better integrate the heterogeneous information of ECG and PCG. Tested on the PhysioNet Challenge 2016 a dataset, the proposed algorithm achieves best values of accuracy, F1 score, precision, and recall at 95.3%, 95.4%, 96.2%, and 99.4%, respectively. Compared to other multimodal convolutional neural network algorithms for ECG and PCG, it shows higher accuracy.

Key words: electrocardiogram (ECG); phonocardiogram (PCG); multimodal feature engineering; Gramian angle fields (GAF); two-stream self-fusion network (TSNet)

心血管疾病是全球范围内人类主要死亡原因之一. 评估心血管系统的状态时, 对心脏功能的分析是一个重要的初始步骤^[1]. 在医学临床上, 有多种诊断方法, 例如心音图、心电图、超声心动

图、CT、心肌酶谱和血管造影术等.

单一的诊断方法难以全面准确地揭示心血管疾病的情况, 因此, 基于多模态特征工程的心血管疾病诊断备受关注. 通常情况下, 医院会采

用成本较低、便于测量的 ECG 和 PCG 来诊断疑似患有心血管疾病的患者^[2-4]. Martins 等^[5]提出了同步采集心电信号和心音信号的方法,以提高心脏病诊断的准确性. Chakir 等^[6]运用传统机器学习的方法,使用 ECG 和 PCG 来诊断心脏疾病,旨在通过使用不同分类器对正常和异常心功能信号进行分类.通过与单模心功能图像(ECG 或 PCG)的分类相比,多模态特征融合方法可以提供更全面、更重要的信息,多模心功能信号在心脏病诊断中更具优势^[7-8].

传统的机器学习方法对手工提取病变特征的质量有很高的要求. Huang 等^[9]和 Al Rahhal 等^[10]尝试使用二维卷积神经网络,通过使用连续小波变换和短时傅里叶变换去获得二维时频图像作为输入.在深度学习的 PCG 分类研究中,大部分研究使用了以 PCG 信号为输入的一维神经网络^[11-12].这些传统的特征工程仅通过预处理和特征提取技术,利用不同的分类器对 PCG 信号和 ECG 信号中提取的特征进行多通道输入的独立训练和测试.一维信号循环神经网络的训练较为困难,同时没有设计针对心脏异常的网络模型,因此在特征提取部分和特征融合部分均未达到较好效果.文献[13-15]使用以短时傅里叶变换

和梅尔倒频谱获得的时频图像作为输入的二维卷积神经网络. Li 等^[16]研究表明使用多模态信号通过 GAF 方法^[17]转换为二维图像相对于一维信号有着明显的优势. GAF 方法是将一维数据转换为二维图像,并且转换后的图像依旧保留了一维时间序列数据的相关性.

本文在多模态研究基础上提出了基于 GAF 和 TSNet 的算法,针对多模态特征设计 TS 模块,能够结合心电信号和心音信号的病变特征进行提取. TS 模块是基于 ECG 信号和 PCG 信号通过 GAF 转换后的图像模型设计的,提高了模型的鲁棒性和准确性.

1 算法模型

1.1 心脏异常分类算法的框架

算法的核心思想是将一维数据转化为动态过程的图像模型,并使用设计的特殊的卷积神经网络 TSNet 进行分类,以检测心脏是否有异常变化.算法分为 2 个阶段.

算法框架如图 1 所示,TSNet 是通过用 TS 模块和分类器来构造的.通过实验验证其在准确率、调和平均数(F1 分数)和召回率等多方面的优越性.

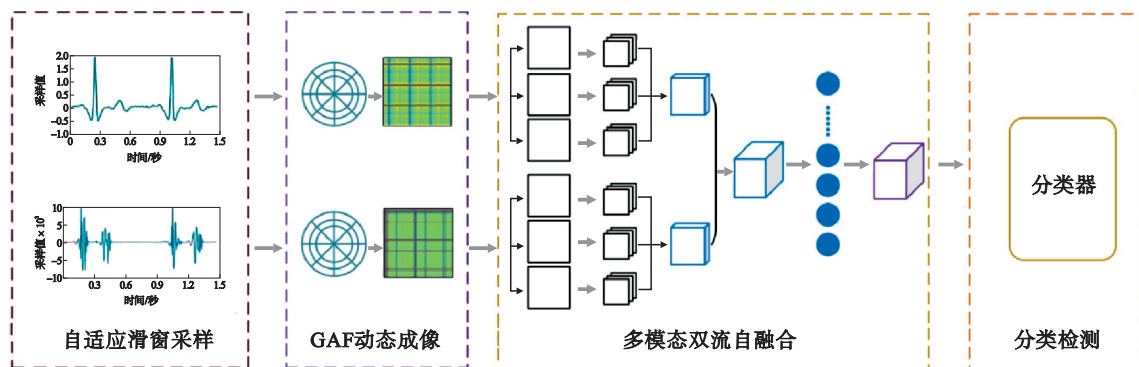


图 1 算法框架

Fig. 1 Framework of the algorithm

第 1 阶段是特征工程设计部分.在本阶段中,设计了建立动态过程图像模型的特征工程.由于存在无效数据,首先进行数据清洗,将无效数据删除.然后从数据集中使用自适应滑窗采样,在处理数据不均衡问题的同时细化为变量子集,将子集中的变量表示在 GAF 中,并将用 ECG 和 PCG 重建的图像连接起来,形成双通道图像模型.

第 2 阶段是心脏异常检测部分.在本阶段中,提出了针对第 1 阶段构建的图像模型的特征网络结构,以提高图像处理效果.在对图像进行病变

检测之前,首先将 TS 模块插入卷积神经网络中,并在训练集中训练整个网络模型.训练后的模型可以直接用于病变的在线检测.

1.2 自适应滑窗采样

PhysioNet Challenge 2016 a 数据集^[18]提供 409 组成对的心电信号和心音信号记录,包括 117 次正常记录和 292 次异常记录,采样频率为 2 000 Hz.由于数据集提供的标记为正常或异常,本文方法的目的是预测信号为正常或异常.在分析数据集信号时,发现部分心电信号被噪声破坏,手动分

析消除了该部分心电信号和相应的心音信号,以增强分类性能.

针对数据集的数据不均衡问题,采用自适应滑窗采样来平衡数据划分子集.根据 2 000 Hz 的采样频率去设定记录的滑窗子集,统计出异常信号采样点数目 Q 和正常信号采样点数目 K .为了保留信号的整体性,对于正常记录的滑窗子集,滑窗的滑动步幅为 500 个采样点;对于异常记录的滑窗子集,滑窗的滑动步幅 S 为

$$S = 500 \times (Q/K). \quad (1)$$

自适应滑窗过程则是根据数据集的正常信号采样点数目和异常信号采样点数目比例,设置采样时的步幅划分子集以达到数据平衡,提高分类性能.图 2 和图 3 分别展示了采样处理后的心电信号和心音信号片段.

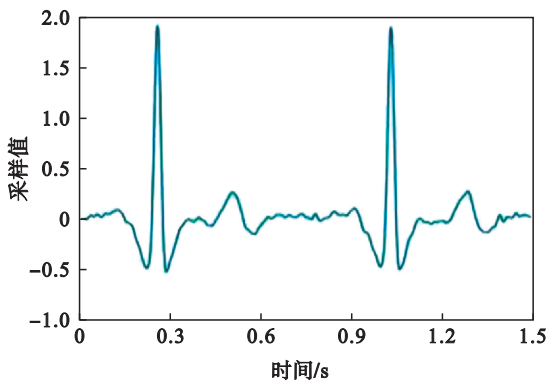


图 2 心电信号示意图

Fig. 2 Schematic diagram of electrocardiosignal




图 3 心音信号示意图

Fig. 3 Schematic diagram of heart sound signal

1.3 GAF 特征工程

一维神经网络在心脏异常识别分类方面的应用并未取得很好的效果,主要是由于循环神经网络的训练较为困难,同时缺乏有效的预训练模型可供使用.相比之下,在语音识别和计算机视觉等领域,卷积神经网络表现出色,因此一维信号在实验中将不再使用,将其转换为二维图像在

二维卷积神经网络中使用.时间序列成像算法主要方式有递归图(recurrence plot, RP)^[19]成像、马尔可夫转换场(Markov transition field, MTF)^[20]成像以及 GAF 成像.实验中使用 GAF 动态成像采样以保留更好的序列特性. GAF 算法将一维序列转为二维图像主要步骤如下:首先是缩放数据的范围;然后是坐标轴变化;最后是三角函数变化.

由 1.2 节得到采样序列,采样点个数为 N ,采样点为 x_i ,序列 X 为

$$X = \{x_1, x_2, \dots, x_i, \dots, x_N\}. \quad (2)$$

第 1 步是对序列 X 进行归一化处理,使 X 的所有子元素的范围都限定在 $[-1, 1]$,归一化后的采样点为 \tilde{x} ,归一化方式为

$$\tilde{x} = \frac{[x_i - \max(X)] + [x_i - \min(X)]}{\max(X) - \min(X)}. \quad (3)$$

第 2 步是将归一化后的一维时间序列从笛卡尔坐标系转换到极坐标系下,其中时间序列数据的值看作极坐标系中的夹角余弦值, ϕ_i 则是采样点夹角,时间被看作极坐标系中的半径 r_i ,具体方法为

$$\phi_i = \arccos(x_i), -1 \leq x_i \leq 1, x_i \in X. \quad (4)$$

$$r_i = \frac{i}{N}, i \in N. \quad (5)$$

从最初的笛卡尔坐标系的序列转换到极坐标系后,需要计算极坐标系两个采样点之间的角度差的三角函数来识别采样点相互之间的时间关联性.本文使用的是 GAF 中的格拉姆求差场,公式为

$$X = [\sin(\phi_i - \phi_j)] = \begin{bmatrix} \sin(\phi_1 - \phi_1) & \dots & \sin(\phi_1 - \phi_n) \\ \vdots & & \vdots \\ \sin(\phi_n - \phi_1) & \dots & \sin(\phi_n - \phi_n) \end{bmatrix}. \quad (6)$$

图 4 和图 5 分别显示了心电信号和心音信号转换后的二维频谱图像.




图 4 心电信号二维频谱

Fig. 4 Two-dimensional spectrum of electrocardiosignal




图5 心音信号二维频谱

Fig. 5 Two-dimensional spectrum of heart sound signal

1.4 TSNet算法分类识别

通过GAF转换后的ECG图像和PCG图像含有不同的信息,一般情况下,所识别的图像是具有3通道的RGB图像或单通道的灰度图像.为了更好地处理所携带的信息并融合两者重要的特征点,提出TSNet算法处理输入图像,TSNet算法由TS模块和深度残差网络(deep residual network, ResNet)^[21]部分组成.

考虑到由于网络层数加深而导致模型退化问题,选用ResNet作为骨干网络去解决模型退化问题;由于实验任务与大型数据集上的计算机视

觉任务相比较复杂性不高,选用ResNet18作为骨干网络.实验保留ResNet18除第1个卷积层以外的网络参数,并且将第1个卷积层替换为实验设计的TS模块并命名为TSNet.

1.4.1 TS模块

TS模块如图6所示,其中定义了一些符号.特征图用 F 来表示; H 和 W 分别为特征图的高和宽; C 为通道数.双流自融合算子 F_{TS} 分别由双流算子 F_T 与自融合算子 F_S 组合而成; F_1 代表特征图1, F_2 代表特征图2, F_3 代表特征图3, F_{T1} 和 F_{T2} 代表按通道将 F_1, F_2, F_3 堆叠一起的特征图, F_T 代表按通道将 F_{T1} 和 F_{T2} 堆叠一起的特征图. f_1 代表 F_T 通过卷积后的特征图, f_2 代表 f_1 通过卷积后的特征图. $R_{H \times W \times 1}$ 表示高和宽分别为 H 和 W 、通道为1的域; $R_{H \times W \times C_2}$ 表示高和宽分别为 H 和 W 、通道为 C_2 的域; F_{TS} 的作用是将多模态输入的单通道映射ECG图像 $X_E \in R_{H \times W \times 1}$ 和单通道映射PCG图像 $X_P \in R_{H \times W \times 1}$ 映射到多通道映射 $F_{TS} \in R_{H \times W \times C_2}$,分为 F_T 映射与自融合模块映射两个部分. $R_{H \times W \times C_1}$ 表示高和宽分别为 H 和 W 、通道为 C_1 的域, F_T 是将多模态输入的 X_E 和 X_P 映射到域中, $F_T \in R_{H \times W \times C_1}$.

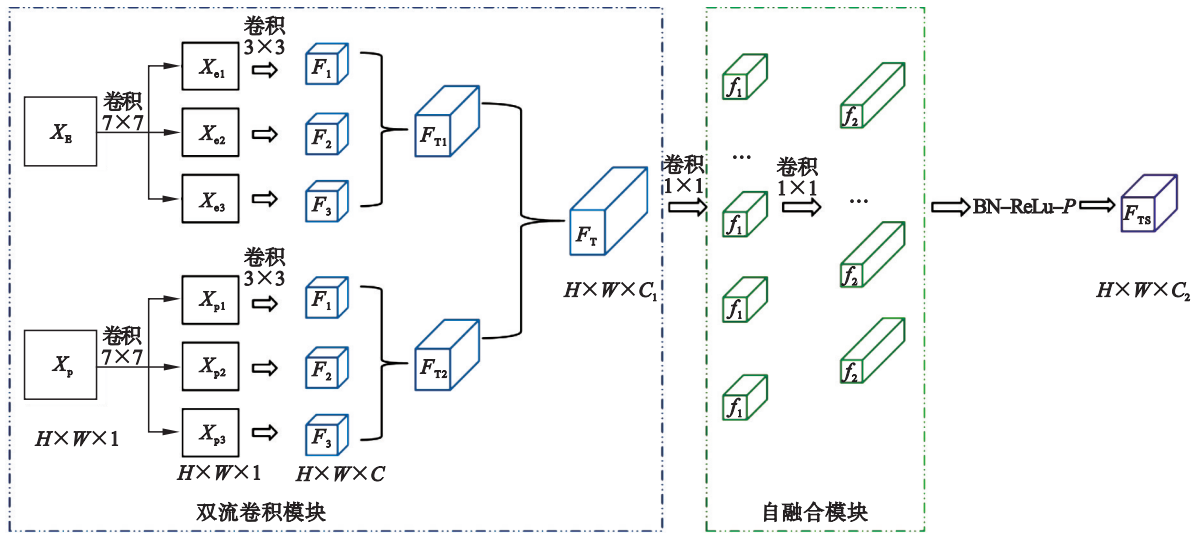


图6 TS模块

Fig. 6 TS module

在双流卷积过程中,对这两个分支应用相同的操作,但不同分支上卷积算子的学习参数值并不相同,因此可以解决ECG和PCG异构信息所引起的异常. F_T 包含2个 7×7 的卷积核 $f_{7 \times 7}$ 和6个 3×3 的卷积核 $f_{3 \times 3}$. $\{X_{e1}, X_{e2}, X_{e3}\}$ 和 $\{X_{p1}, X_{p2}, X_{p3}\}$ 是由 $f_{7 \times 7}$ 与 $\{X_E, X_P\}$ 卷积得出的中间特征图.

$$\{X_{e1}, X_{e2}, X_{e3}\} = X_E * f_{7 \times 7}, \quad (7)$$

$$\{X_{p1}, X_{p2}, X_{p3}\} = X_P * f_{7 \times 7}. \quad (8)$$

F_T 算子则是由 $\{X_{e1}, X_{e2}, X_{e3}\}$ 和 $\{X_{p1}, X_{p2}, X_{p3}\}$ 与 $f_{3 \times 3}$ 卷积后堆叠得出.

$$F_T = \{\{X_{e1}, X_{e2}, X_{e3}\}, \{X_{p1}, X_{p2}, X_{p3}\}\} * f_{3 \times 3}. \quad (9)$$

F_S 包括两个 1×1 的卷积核 $f_{1 \times 1}$ 作为全连接层,将输入 $F_T \in R_{H \times W \times C_1}$ 映射到特征图 $F_{TS} \in R_{H \times W \times C_2}$ 上.在 F_T 中,每个特征图是直接拼接合并的,不同

通道之间的信息互相之间依然独立,并且通道的维度与后续的网络输入的维度不匹配.因此采用两层全连接来实现不同通道的信息融合,并使其适应后续网络输入的维度.

$$F_s = \{f_{1 \times 1}, f_{1 \times 1}\}. \quad (10)$$

$$F_{TS} = P(\delta(\beta(F_T * f_{1 \times 1} * f_{1 \times 1}))). \quad (11)$$

式中: $\delta(\cdot)$ 表示 ReLu 激活函数,选用 ReLu 函数作激活函数增加网络的非线性; $\beta(\cdot)$ 表示批量归一化方法(batch normalization, BN); $P(\cdot)$ 表示最大池化函数.

1.4.2 TSNet算法整体结构

选用 ResNet 18 作为骨干网络,将 TS 模块插入 ResNet 18 中.由于低级特征图包含的信息不丰富,导致输入图像的特征引起的问题在低级卷积部分较为严重,因此采用 TS 模块来代替 ResNet 18 的第 1 层卷积结构.将整体的残差结构设为 f_r ,全连接层表示为 f_c .

ResNet 网络结构表达为

$$Y = R(X) = f_c(f_r(f_1(X))). \quad (12)$$

TSNet 算法网络结构表达为

$$Y_1 = T(X) = f_c(f_r(f_{TS}(X))). \quad (13)$$

2 实验验证

实验在 PhysioNet Challenge 2016 a 数据集中进行验证.数据集标签由正常和异常组成.将数据集按数据数量 85:15 的比例分为训练集和测试集.实验内容主要包括识别算法的对比实验以及多指标评估.数据集异常信号的原采样点数量为 7 821 691 个,数据集正常信号的原采样点数量为 3 604 401 个. ECG 信号和 PCG 信号同时经滑窗采样后的子集进行格拉姆求差场处理,获得的正常信号和异常信号转换后的二维频谱图像总数量为 13 490 张和 13 416 张.

2.1 实验参数与指标

实验中所用框架为 PyTorch,在 Intel SkyLake 6151 3.0 GHz CPU, 64.0 RAM 和 NVIDIA V100-PCIe-32G GPU 的云服务器环境下进行.使用动量优化器的随机梯度下降更新网络参数,学习率初始化为 0.000 8,损失函数选用交叉熵.为防止过拟合问题且减少训练时间,增加了根据损失函数变化的学习率衰退策略. TSNet 算法的其他实验参数见表 1.

选用准确率、召回率、精确率和 F1 分数 4 个

指标来评估分类结果的性能.召回率表示正确预测正样本的比例;准确率表示正确预测样本的总体比例;精确率表示正确预测正样本的比例相对于所有预测为正样本的比例;F1 分数是召回率和精确率的调和均值.表 2 中给出了评估指标及其表达式. T_p 为真阳性样本数, F_p 为假阳性样本数, T_N 为真阴性样本数, F_N 为假阴性样本数.

表 1 实验参数

Table 1 Experimental parameters	
模型配置	实验参数
骨干网络	ResNet-18
图像尺寸/像素	200×200
迭代次数	50
批量大小/个	128
通道数/个	10, 20, 64

表 2 评估指标及其表达式

Table 2 Evaluation indicators and expressions	
评估指标	表达式
准确率	$\frac{T_p + T_N}{T_p + T_N + F_p + F_N} \times 100\%$
召回率	$\frac{T_p}{T_p + F_N} \times 100\%$
精确率	$\frac{T_p}{T_p + F_p} \times 100\%$
F1 分数	$\frac{2 \times \text{精确率} \times \text{召回率}}{\text{精确率} + \text{召回率}}$

2.2 指标评估

2.2.1 GAF 转换的有效性

采用 GAF 作为一维时间序列转换为二维图像的方法.实验分别采用 GAF, MTF 和 RP 在 ResNet 网络中进行对比.

由表 3 可以看出,相对于 MTF 和 RP 的转换方式, GAF 转换方式的准确率、召回率、精确率、F1 分数有着明显的提升,分别增加到 92.6%, 99.9%, 96.3%, 92.8%.

损失函数曲线是评估模型的指标之一,由图 7 可以看出, GAF 转换方式要比其他 2 种转换方式模型泛化能力更强,训练速度更快.

表 3 对比实验

Table 3 Comparative experiment				
模型	准确率	召回率	精确率	F1 分数
GAF+ResNet	92.6	99.9	96.3	92.8
MTF+ResNet	90.9	99.7	100.0	90.9
RP+ResNet	89.6	99.8	88.4	90.1

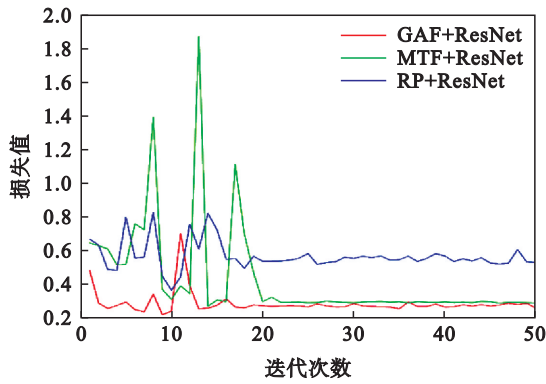


图7 对比实验损失函数曲线

Fig. 7 Loss function curves of comparative experiment

2. 2. 2 TS 模块的有效性

为验证 TS 模块的有效性,使用 ResNet, 挤压与激励网络 (squeeze and excitation network,

SEnet)^[22], 卷积块注意力模块 (convolutional block attention module, CBAM)^[23] 验证 TS 模块的有效性. 并将 TS 模块插入 ResNet, CBAM 中, 比较 TS 模块带来的影响, 其中 CBAM 和 SEnet 也使用 ResNet 作为骨干网络. SEnet 是一种具有通道注意力的残差网络, CBAM 是一种具有空间和通道注意力机制的残差网络. 表 4 为在测试集上的 5 次消融实验多指标评估的综合结果. 考虑到收敛速度且保证精度以及为了消除过拟合的前提下, 采用了根据损失值去变化学习率衰退策略, 这种学习率的变化相对于网络模型更为精确, 学习率在初始时设置较大以减少训练时间, 随着损失值衰减来修改学习率使其接近最优解. 因此在训练初期网络的曲线波动会较大.

表 4 多指标评估结果 (均值±标准差)

Table 4 Results of multiple indicator evaluation (mean ± standard deviation)

模型	准确率	召回率	精确率	F1 分数
ResNet	90.36±2.27	96.16±2.55	93.04±1.71	90.44±2.42
TSNet	92.21±0.95	97.84±1.90	94.58±1.28	92.24±1.04
SEnet	90.97±2.78	96.38±3.45	92.40±2.38	91.08±2.87
CBAM	90.75±2.38	94.50±3.49	92.90±2.04	90.74±2.49
TS+CBAM	89.76±1.72	94.36±3.37	92.90±1.67	89.96±1.67

TS 模块加入的基础网络与通过注意力机制分配通道权重的基础网络改进方法相比, 网络收敛速度有很大提升, 精度指标更高. 使用 TS 模块进行通道处理具有很大的优势.

由表 4 可以看出, TS 模块的添加, 可以提高模型的性能. 相对于 CBAM, TS 模块并没有提高其性能, 说明两者结构并不能很好的融合, 但没有导致性能的严重下降, 并增强了其稳定性. 相对于 ResNet 网络, TS 模块不仅增强了其性能, 还使其稳定性有所提升. 实验结果表明, 相比于其他网络, 无论是准确率、精确率、召回率还是 F1 分数, TSNet 算法都有显著优势.

图 8 为不同网络模型下的损失函数曲线. 可以看出 TS 模块并不能完美适合 CBAM 网络模型, TSNet 的网络模型相较于其他模型更好地学到了训练数据中的模式和规律. 说明模型具有更好的泛化能力, 即对于新的未见过的数据, 模型可以给出较为准确的预测结果.

图 9 为网络对比实验图, 可见模型收敛后的准确率为 0.88%~0.91%, TSNet 网络的模型表现效果最好, 并且可以看出添加了 TS 模块的网络

模型准确率变化更小, 模型更加稳定; 这些模型的召回率很接近, TSNet 网络模型的召回率是最高的, 这意味着 TS 模块与 ResNet 组合的网络模型拥有更少的漏诊率; TSNet 的网络模型的精确率更高, 而精确率高可以带来更少的误诊率、更少的假阳性率、提高预测结果的可靠性和提高决策的精度等好处; TSNet 网络模型拥有更高的 F1 分数, 更好地平衡精确率和召回率、提高模型的分能力.

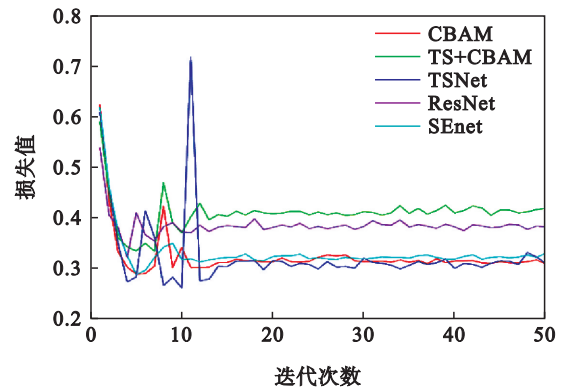


图8 网络损失函数曲线

Fig. 8 Network loss function curves

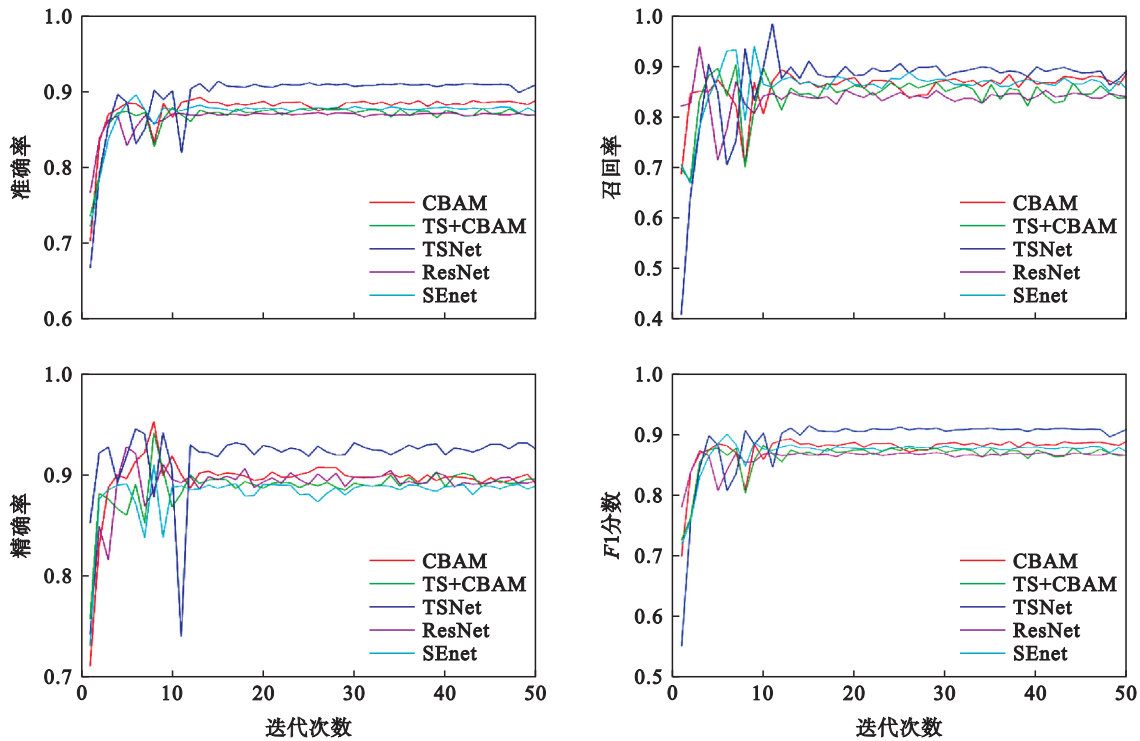


图9 网络对比实验图

Fig. 9 Diagrams of network comparisons experiments

3 结 语

本文使用 ECG 和 PCG 作为多模态数据输入,通过 GAF 实现一维信号转换为二维图像,并且提出 TSNet 算法提高心脏异常识别的性能.在实验中,证实了选用 GAF 作为一维信号转为二维图像的优势,同时通过对比实验得出在不同指标下的评估结果,TS 模块的有效性以及可靠性.证实 TSNet 算法相对于其他网络结构在心脏异常检测中有更好的效果.

参考文献:

- [1] Sookram C, Munodawafa D, Phori P M, et al. Who's supported interventions on salt intake reduction in the sub-Saharan Africa region [J]. *Cardiovascular Diagnosis and Therapy*, 2015, 5(3): 186-190.
- [2] Hettiarachchi R, Haputhanthri U, Herath K, et al. A novel transfer learning-based approach for screening pre-existing heart diseases using synchronized ECG signals and heart sounds [C]//2021 IEEE International Symposium on Circuits and Systems (ISCAS). Daegu, 2021: 1-5.
- [3] Rautaharju P M. Eyewitness to history: landmarks in the development of computerized electrocardiography [J]. *Journal of Electrocardiology*, 2016, 49(1): 1-6.
- [4] Leatham A. Auscultation of the heart and phonocardiography [J]. *Postgraduate Medical Journal*, 1971, 47(550): 582.
- [5] Martins M, Gomes P, Oliveira C, et al. Design and evaluation of a diaphragm for electrocardiography in electronic stethoscopes [J]. *IEEE Transactions on Biomedical*

Engineering, 2020, 67(2): 391-398.

- [6] Chakir F, Jilbab A, Nacir C, et al. Recognition of cardiac abnormalities from synchronized ECG and PCG signals [J]. *Physical and Engineering Sciences in Medicine*, 2020, 43(2): 673-677.
- [7] Li J H, Ke L, Du Q, et al. Multi-modal cardiac function signals classification algorithm based on improved D-S evidence theory [J]. *Biomedical Signal Processing and Control*, 2022, 71: 103078.
- [8] Singh S A, Singh S A, Devi N D, et al. Heart abnormality classification using PCG and ECG recordings [J]. *Computación y Sistemas*, 2021, 25(2): 381-391.
- [9] Huang J S, Chen B Q, Yao B, et al. ECG arrhythmia classification using STFT-based spectrogram and convolutional neural network [J]. *IEEE Access*, 2019, 7: 92871-92880.
- [10] Al Rahhal M M, Bazi Y, Al Zuair M, et al. Convolutional neural networks for electrocardiogram classification [J]. *Journal of Medical and Biological Engineering*, 2018, 38(6): 1014-1025.
- [11] Potes C, Parvaneh S, Rahman A, et al. Ensemble of feature-based and deep learning-based classifiers for detection of abnormal heart sounds [J]. *Computing in Cardiology*, 2016, 43: 621-624.
- [12] TSchannen M, Kramer T, Marti G, et al. Heart sound classification using deep structured features [C]//2016 Computing in Cardiology Conference (CinC). Vancouver: IEEE, 2016: 565-568.
- [13] Wibawa M S, Maysanjaya I M D, Novianti N K D P, et al. Abnormal heart rhythm detection based on spectrogram of heart sound using convolutional neural network [C]//The 6th International Conference on Cyber and IT Service Management (CITSM 2018). Parapat: IEEE, 2018: 1-4.

(下转第 1520 页)