

## 基于双向选择性状态空间模型的心电自动诊断模型

林铭俊<sup>1</sup>, 温耀棋<sup>1</sup>, 张鑫<sup>1</sup>, 洪永<sup>1</sup>, 陈超敏<sup>1</sup>, 吴煜良<sup>2</sup>

1. 南方医科大学生物医学工程学院, 广东 广州 510515; 2. 南方医科大学第十附属医院(东莞市人民医院)肿瘤放射治疗中心, 广东 东莞 523059

**【摘要】**针对现有心电自动诊断模型在长时依赖性学习上存在的局限性,提出一种结合双向选择性状态空间模型(BiMamba)与残差多尺度感受野模块的12导联长时心电信号自动诊断模型(BiMamba-RMSF)。首先,设计具有残差连接的多尺度感受野模块实现更广泛的特征提取与融合;其次,引入BiMamba模块通过正向和反向的时序处理方式,提高模型的时序建模能力;最后,分类器对来自BiMamba的特征进行处理实现心电多标签分类任务。从PTB-XL数据集上提取5个主诊断类别的数据,进行五折交叉验证实验。对比实验结果显示,BiMamba-RMSF的平均准确率达到89.42%,平均AUC达到93.56%,平均F1分数达到72.85%,各指标均高于其他4个对比心电自动诊断模型,且通过消融实验进一步验证BiMamba模块的有效性。实验结果表明本文模型在12导联长时心电信号多标签分类任务上具有较高精度。

**【关键词】**心电信号;心电自动诊断模型;选择性状态空间模型;深度学习

**【中图分类号】**R318

**【文献标志码】**A

**【文章编号】**1005-202X(2025)04-0489-07

### Automatic ECG diagnosis model based on bidirectional selective state space model

LIN Mingjun<sup>1</sup>, WEN Yaoqi<sup>1</sup>, ZHANG Xin<sup>1</sup>, HONG Yong<sup>1</sup>, CHEN Chaomin<sup>1</sup>, WU Yuliang<sup>2</sup>

1. School of Biomedical Engineering, Southern Medical University, Guangzhou 510515, China; 2. Radiation Oncology Center, Dongguan People's Hospital/the Tenth Affiliated Hospital of Southern Medical University, Dongguan 523059, China

**Abstract:** To address the limitations of the existing automatic electrocardiogram (ECG) diagnosis models in learning long-term dependencies, an automatic 12-lead long-term ECG signal diagnosis model which combines bidirectional selective state space model (bidirectional mamba, BiMamba) with residual multi-scale receptive field block (RMSF) is proposed: (1) designing a multi-scale receptive field module with residual connections to realize more extensive feature extraction and fusion; (2) introducing BiMamba block to enhance the model's temporal modeling capability by employing both forward and backward temporal processing; (3) using the classifier to process features from BiMamba for accomplishing multi-label ECG classification. Five major diagnostic categories from the PTB-XL dataset are extracted and subjected to 5-fold cross-validation experiments. The experimental results from the comparative study show that BiMamba-RMSF achieves an average accuracy of 89.42%, an average AUC of 0.9356, and an average F1 score of 72.85%, outperforming the other 4 automatic ECG diagnosis models. Additionally, ablation study further validates the effectiveness of BiMamba block. It is demonstrated that the proposed model has a high precision in the multi-label classification for 12-lead long-term ECG signals.

**Keywords:** electrocardiogram; automatic electrocardiogram diagnosis model; elective state space model; deep learning

### 前言

根据世界卫生组织(World Health Organization, WHO)报道,心血管疾病已成为全球范围内的主要健康问题,也是导致死亡的主要原因<sup>[1]</sup>。随着医学技术

的不断进步,心电图(Electrocardiogram, ECG)、动态监测与植入式设备等技术显著提高了心血管疾病的监测和诊断能力,使得医疗干预更加及时与有效。ECG是一种诊断性电生理信号,其记录了心脏在一定时间内的心律和电位变化等信息<sup>[2]</sup>。现代ECG设备及其分析技术的发展已能辅助临床医生在时间域、空间域和频率域上对心脏电生理活动进行多角度分析,显著提高了临床诊断的准确性和可靠性。

心电自动诊断模型已成为人工智能技术在心电领域的一大研究重点。这类模型通常是根据不同疾病的ECG形态模式差异对患者的心电信号进行分类的深度学习模型<sup>[3]</sup>。这些模型的层次化架构使它们

**【收稿日期】**2025-01-05

**【基金项目】**国家重点研发计划(2023YFC2414502)

**【作者简介】**林铭俊,硕士研究生,研究方向:生物医学工程,E-mail: 1078350560@qq.com

**【通信作者】**陈超敏,教授,博士生导师,研究方向:医疗仪器与人工智能,E-mail: 571611621@qq.com;吴煜良,主任技师,研究方向:医疗仪器与人工智能,E-mail: 84833910@qq.com

能够准确学习高维数据的潜在特征结构<sup>[4]</sup>,并给出较为准确的辅助诊断建议,由此消除随机的人为错误,在一定程度上有效辅助临床医生进行ECG诊断,提高临床效率。

目前,主要的心电自动诊断模型可分为心拍分类识别以及长时导联分类识别两大类。在心拍分类识别模型中,Ahmed等<sup>[5]</sup>通过微调一维卷积神经网络(Convolutional Neural Network, CNN)的超参数,实现快速的心拍分类任务。Pandey等<sup>[6]</sup>采用小波自适应阈值变换对心电信号进行去噪处理,并将去噪后的心电信号输入到CNN中进行训练,该模型在心拍分类任务中的平均准确率能达到99.4%。Hannun等<sup>[7]</sup>在CNN的基础上,引入了残差连接结构用于12种心拍分类,其网络性能甚至超过了一些有经验的临床电生理医生。然而,心拍分类识别任务对训练数据的处理要求较高。具体来说,临床上获得的长时导联心电信号通常需要经过一系列繁琐的步骤才能转换为心拍信号,并输入到模型中进行识别。此外,心拍分类识别模型的局限性在于,它无法从患者整体心电信号的角度进行全面分析,这可能影响某些心血管疾病的诊断。

在长时导联分类识别中,庞伟等<sup>[8]</sup>将卷积神经网络VGG16与文本神经网络TextCNN模型进行融合,实现12导联心电信号的诊断分类任务,该模型在小样本学习中达到了83.64%的平均分类准确率。Coppola等<sup>[9]</sup>提出一种心电信号基础模型HuBERT-ECG,该模型通过在大型心电数据集上进行自监督预训练,从而实现多种心血管疾病的自动诊断任务。Bui等<sup>[10]</sup>提出一种多模态时频谱重建网络TSRNet,旨在通过提取心电信号时域与频域中的特征,提高模型的鲁棒性以及性能。Kim<sup>[11]</sup>于2024年提出ECG-JEPA模型,该模型通过在潜在空间中进行遮掩建模,并引入跨模式注意力机制,显著提升了模型在12导联心电信号上的分类性能。

尽管现有的心电自动诊断模型已在心拍分类和长时导联分类识别方面取得了显著进展,但在长时依赖性学习上仍存在一定的局限性。在12导联心电信号自动诊断领域,让模型有效提取心电信号时序特征,即提高模型的长时依赖能力至关重要。目前,选择性状态空间模型(Mamba)已被广泛应用于自然语言以及序列数据处理领域,其能有效增强模型的时序建模能力与长时依赖性<sup>[12]</sup>。由此,本文提出了一种基于双向选择性状态空间模型(Bidirectional Mamba, BiMamba)<sup>[13]</sup>和具有残差连接的多尺度感受野模块(Residual Multi-scale Receptive Field Block, RMSF)的心电自动诊断模型BiMamba-RMSF。与已

有深度学习方法不同,本文模型通过引入BiMamba,提升模型对12导联长时心电信号的时序特征学习能力,更好地捕捉并利用心电信号中的时间相关性以及动态模式,从而提升心电诊断模型的准确性与鲁棒性。

## 1 数据集与数据处理

本文实验数据均来源于一个全面且公开可访问的临床12导联ECG数据集——PTB-XL数据集<sup>[14-16]</sup>。该数据集包含了21 799份临床12导联10 s ECG,这些数据来源于1989年10月~1996年6月就诊的18 885名患者。该数据集提供100 Hz和500 Hz两种采样频率的数据,为减少计算资源消耗,后续实验使用采样频率为100 Hz的心电信号作为训练、验证以及测试数据。PTB-XL数据集提供了涵盖诊断、心电形态和节律等71种不同的心电注释,这些注释均遵循SCP-ECG标准<sup>[17]</sup>。在诊断注释方面,PTB-XL数据集提供了5个主诊断类别以及24个子诊断类别,其中5个主诊断类别分别为正常ECG(Normal ECG, Norm)、心肌梗死(Myocardial Infarction, MI)、ST-T段改变(ST-T Changes, STTC)、传导紊乱(Conduction Disturbances, CD)和心房/心室肥大(Hypertrophy, HYP)。每个主诊断类别都聚合了相关的子诊断类别来提供更详细的诊断信息,例如MI主类下可细分为下壁心肌梗死(Inferior Myocardial Infarction, IMI)或前壁心肌梗死(Anterior Myocardial Infarction, AMI)等子诊断类别。多标签注释系统表明,每个ECG通常都被分配了更广泛的主类诊断和更为细致的子类诊断注释,反映了心脏诊断过程的复杂性与层次性。

为了处理5个主诊断类别的标签并将其用于模型训练,笔者采用了one-hot编码方法。具体而言,对于每个ECG样本,首先将其主诊断类别标签转换为一个五维的one-hot编码向量,其中每一维代表一个主诊断类别的存在或缺失,例如同时属于NORM和MI类别的心电信号,其标签组合为[NORM, MI],one-hot标签为[1, 1, 0, 0, 0]。对于那些不属于诊断注释类别的411例样本(如心电形态与节律方面的注释),将其标签设置为全零的one-hot编码向量[0, 0, 0, 0, 0],以确保数据的完整性,并帮助模型保持较强的泛化能力和鲁棒性。通过这种方式,数据集的标签不仅能够准确反映每个样本的主要诊断类别,还能通过多标签的one-hot编码支持更复杂的ECG分析,进一步提升模型在处理各种诊断任务时的效果和表现。

数据集的标签分布详细信息如图1所示,对于主

诊断类别标签组合样本量少于 50 的 5 组标签组合, 考虑到样本量过小可能导致训练过程中产生较大的偏差或影响模型的稳定性, 决定将这 5 组标签组合 (共计 38 例样本) 剔除, 以确保数据集的代表性和训练效果。数据清洗后的数据集样本量为 21 761 例, 剩余的标签组合为 18 组。本研究使用上述 5 个主诊断类别组合的心电信号进行模型训练, 将数据集按

照 8:2 的比例从各个主诊断类别组合中进行随机抽样, 划分后训练验证集以及测试集样本数目分别为 17 408 以及 4 353 例, 共计 21 761 例样本。后续进行五折交叉验证, 将训练验证集 17 408 例样本按照 8:2 的比例划分为训练集与验证集, 分别为 13 926 以及 3 482 例。




图 1 PTB-XL 数据集多标签分布情况  
Figure 1 Multi-label distribution of the PTB-XL dataset

## 2 模型介绍

### 2.1 总体模型

在本研究中,笔者构建了一个集成深度学习网络模型(BiMamba-RMSF)。该模型的输入为 12 导联心电信号,首先通过一维卷积模块提取时序特征。处理后的特征通过两个 RMSF 进行进一步提取和增强。在 RMSF 中,模型采用了不同卷积核尺寸的卷积操作和层归一化策略,通过逐步增加输出通道数,模型能够扩展感受野并捕捉到心电信号中不同尺度的时空特征。此外,在残差连接中使用扩展卷积层来捕捉更广泛的特征信息,并有效促进不同层次特征的融合,提高模型的稳定性。

在特征提取后,模型通过 BiMamba 模块进一步提升时序建模能力。BiMamba 模块结合双向 Mamba 模型,通过正向和反向的处理方式,能够更好地捕捉长时依赖关系,从而有效提高 12 导联心电信号分类任务的表现。为了进一步增强模型的泛化能力,在分类器前加入全局平均池化层以减少计算复杂度。最后,模型通过由两个全连接层和 SELU 激活函数组成的分类器 Classifier,实现多标签心电信号的诊断任务。模型的网路结构如图 2 所示,模型的具体参数设置如表 1 所示。

### 2.2 BiMamba

Mamba 的主要思想可通过状态空间模型(State Space Model, SSM)<sup>[18]</sup>的线性状态空间转移方程来描述,如式(1)所示。该类模型通过  $N$  维隐藏状态  $h(t)$  来将一维输入序列  $x(t)$  映射至一维输出序列  $y(t)$ 。

$$\begin{aligned} h(t) &= Ah(t-1) + Bx(t) \\ y(t) &= Ch(t) + Dx(t) \end{aligned} \tag{1}$$

其中,  $A$ 、 $B$ 、 $C$ 、 $D$  为状态转移矩阵。这些矩阵构成了 SSM 的核心,它们不仅定义了系统状态随时间的变化规律,还确保了模型能够捕捉输入数据与输出之间的复杂动态关系。

Mamba 模型在循环扫描过程中,利用 SSM 对上下文信息进行编码。其选择机制能够控制影响隐藏状态及随后嵌入更新的输入元素<sup>[19]</sup>。Mamba 将 H3 (Hungry Hungry Hippos)<sup>[20]</sup>的基本结构与神经网络中常见的门控多层感知器(Gated Multi-Layer Perceptron, Gated MLP)<sup>[12]</sup>相结合,其结构如图 3 所示。输入信号首先经过均方根归一化处理,增强模型稳定性。然后,数据通过两个线性投影层进行特征变换,并使用卷积层提取特征,最后通过激活函数增加非线性表达能力。选择性状态空间模型用于建模时序依赖,捕捉时序的动态变化。相较于 SSM 压缩时序所有的历史信息,Mamba 通过参数化的 SSM



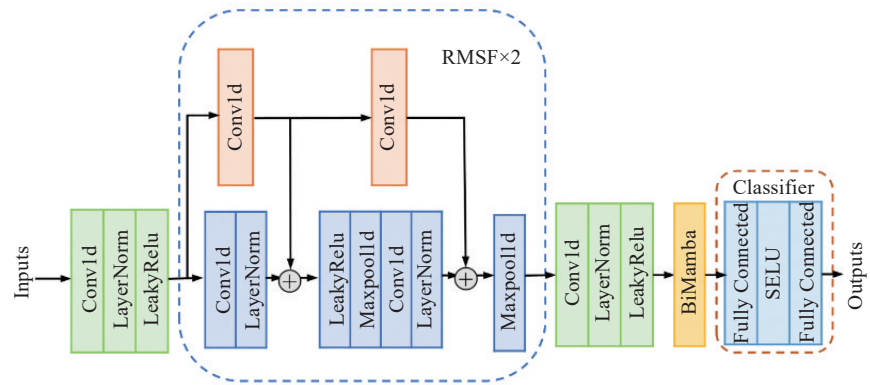


图 2 BiMamba-RMSF 模型结构示意图  
Figure 2 BiMamba-RMSF model structure

表 1 BiMamba-RMSF 模型参数设置  
Table 1 Parameter configuration of BiMamba-RMSF model

序号	模块	输入输出通道与卷积核大小
1	一维卷积模块 1	(input:12, output:32), kernel size:5
2	RMSF 1	(input:32, output:64), kernel size:7, extra kernel size:7 (input:64, output:128), kernel size:5, extra kernel size:8
3	RMSF 2	(input:128, output:256), kernel size:5, extra kernel size:5 (input:256, output:256), kernel size:5, extra kernel size:8
4	一维卷积模块 2	(input:256, output:128), kernel size:5
5	BiMamba 模块	(input:256, output:128), kernel size:5, state=64
6	分类器	(input:128, output:64), (input:64, output:5)

input 为输入通道数,output 为输出通道数,kernel size 为卷积核大小,extra kernel size 为残差连接中扩展卷积层的卷积核大小,state 为 BiMamba 的状态维度大小

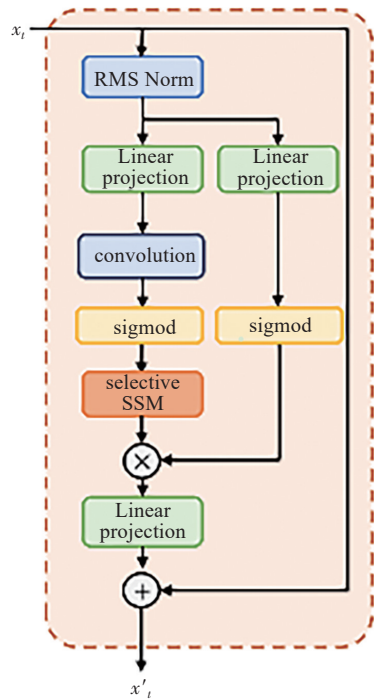


图 3 Mamba 模型结构示意图  
Figure 3 Mamba structure

输入,让模型对输入的时序信息进行有选择性的处理,这种选择机制允许 Mamba 只关注相关数据特征,从而提高数据处理效率。

本文引入的 BiMamba 模块通过正向和反向的 Mamba 变换结合使用,有效捕捉心电信号中的时序依赖关系,其架构如图 4 所示。BiMamba 首先对输入信号特征进行双向 Mamba 变换,正向和反向的处理方式能全面捕捉信号特征的前后依赖性,有助于提高模型对心电信号的理解能力。变换后的信号特征经过层归一化操作,保证了网络稳定性,避免了梯度消失或爆炸等问题。接着,前馈神经网络通过扩展通道维度和 GELU 激活函数的引入,增强了模型的表达能力,使其能够提取更为复杂的信号特征。

为保证信号特征的有效传递和保留,BiMamba 还采用了残差连接,将输入信号特征与 Mamba 变换后的输出相加,避免了信息丢失。对于 12 导联 10 s 心电信号,BiMamba 能够有效捕捉不同导联之间的时序依赖关系,提升模型对信号的分析能力。此外,层归一化和残差连接机制提升了模型的鲁棒性,能够确保模型在输入数据有噪声干扰的情况下仍能进行有效的特征提取。

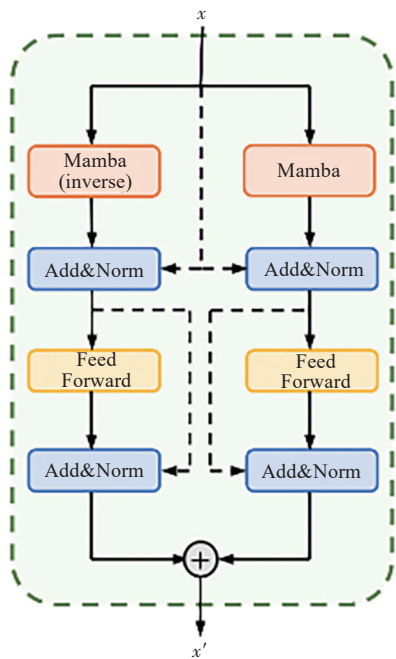


图4 BiMamba 模型结构示意图  
Figure 4 BiMamba structure

3 实验方案

3.1 模型训练与对比实验方案

本实验在 CUDA 版本为 11.8, CPU 为 Intel(R) Xeon(R) Gold 6330, 显存为 48 GB, GPU 为 NVIDIA RTX A6000 的设备上进行部署。实验编程语言使用 Python 3.10.13, 深度学习框架为 Pytorch 1.13.1。

为验证本研究提出的 BiMamba 模型在 12 导联心电信号自动诊断任务中的性能, 将其与近年来提出的 12 导联多标签心电自动诊断模型 Xresnet1d101<sup>[21]</sup>、Inception1d<sup>[22]</sup>、ResU2D-LC<sup>[23]</sup>、ResU-Dense<sup>[24]</sup>进行对比。对比实验中所列举的模型均基于 PTB-XL 数据集的 12 导联 10 s 心电信号进行研究, 且采用相同的数据集划分比例和损失函数进行训练和测试, 以保证实验结果的一致性。实验采用五折交叉验证和早期停止策略, 若验证集的损失在连续 5 个 epoch 内未发生下降, 则停止训练, 保存验证集损失最小的模型权重。为确保实验条件一致, 本文模型、消融实验及对比模型均在相同的优化器和初始学习率下进行训练。具体实验超参数设置见表 2。

3.2 评估指标

在本研究中, 采用了准确率 (Accuracy)、受试者工作特征 (Receiver Operating Characteristic, ROC) 曲线下面积 (Area Under Curve, AUC)、精确率 (Precision)、召回率 (Recall)、F1 分数 (F1 Score) 多项评价指标来全面评估 12 导联 10 s 5 类别多标签心电分类模型的性能。准确率用于衡量模型整体分类的

表 2 实验超参数设置  
Table 2 Experimental hyperparameter settings

超参数	数值/设置
优化器	AdamW
权重衰减	0.01
学习率	0.000 5
损失函数	BCEWithLogitsLoss
Epochs	30

正确性, 表示模型正确预测的样本占有所有样本的比例。AUC 反映模型区分不同类别的能力, ROC 曲线的横坐标为假阳性率 (False Positive Rate, FPR), 纵坐标为真阳性率 (True Positive Rate, TPR), AUC 值越高, 模型的分类能力越强。F1 评分则综合了精确度和召回率, 特别适用于类别不平衡的任务, 它通过调和平均精确度和召回率的方式, 提供了模型分类性能的平衡度。召回率主要评估模型识别目标类别的能力, 关注的是模型在正类中的表现。具体而言, 准确率、F1 评分和召回率等指标有助于全面评价模型在 5 类别心电信号中的分类效果, 尤其是在多标签、多类别任务中, 它们能够有效地反映模型对不同心电信号的识别精度和敏感度。每个指标的定义如下:

$$\text{Accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}} \tag{2}$$

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \tag{3}$$

$$\text{Recall} = \text{TPR} = \frac{\text{TP}}{\text{TP} + \text{FN}} \tag{4}$$

$$\text{FPR} = \frac{\text{FP}}{\text{TN} + \text{FP}} \tag{5}$$

$$\text{F1 score} = \frac{2(\text{Precision} \times \text{Recall})}{\text{Precision} + \text{Recall}} \tag{6}$$

其中, 真阳性 (True Positive, TP) 指模型正确预测为某一心电诊断类别 (如 Norm、MI 等) 的样本数量; 真阴性 (True Negative, TN) 指模型正确预测为非该类心电诊断类别的样本数量; 假阳性 (False Positive, FP) 指模型错误预测为该类别 (如将 Norm 错误预测为 MI) 的样本数量; 假阴性 (False Negative, FN) 指模型错误预测为非该类别 (例如, 将 MI 错误预测为 Norm) 的样本数量。

4 结果与分析

4.1 对比实验结果

对比实验方案中, 各模型在测试集上的评估指标如表 3 所示。

从实验结果可以看出, BiMamba-RMSF 模型在所有评估指标上均表现优异, 尤其是在平均准确率 (89.42%) 和平均 AUC (93.56%) 上显著领先于其他模

表3 不同模型分类性能对比 ( $\bar{x}\pm s, \%$ )

Table 3 Comparison of classification performance among different models ( $Mean\pm SD, \%$ )

模型	准确率	AUC	精确率	召回率	F1 分数
Xresnet1d101	87.11±0.53	90.85±0.56	82.80±1.54	58.71±2.97	67.31±2.35
Inception1d	86.30±0.39	93.26±0.25	83.44±2.10	64.74±1.81	71.51±0.77
ResU2D-LC	87.33±0.80	91.31±1.03	79.61±3.34	61.96±1.42	69.03±1.26
ResU-Dense	88.26±0.20	91.95±0.31	80.31±1.41	65.00±1.78	70.94±1.25
BiMamba-RMSF	89.42±0.18	93.56±0.19	83.95±1.04	65.56±1.93	72.85±1.06

型,表明其在心电信号多标签分类任务中的卓越性能。该模型在平均精确率(83.95%)和平均F1分数(72.85%)上的表现同样突出,显示出其较强的精确性和对不平衡类别的良好处理能力。结合BiMamba-RMSF具有较小的标准差,进一步说明该模型在各项任务中不仅表现较好,而且在不同测试情况下的稳定性也较强。相比之下,Xresnet1d101和ResU2D-LC模型虽然在AUC上表现不错,但两者的平均精确率(82.80%与79.61%)和平均召回率(58.71%与61.96%)较低,说明上述两个模型虽然在区分正负样本时表现较好,但在实际的正类预测中容易出现误判以及漏判的情况。Inception1d和ResU-Dense模型在各项指标上的表现较为均衡,特别是Inception1d,在平均AUC和平均精确率上表现与BiMamba-RMSF相近,但仍不及BiMamba-RMSF模型。对于BiMamba-RMSF模型而言,RMSF能够从不同尺度提取心电信号的时空特征,有效捕捉到信号中的细微变化;而BiMamba模块结合了双向Mamba模型,通过正向和反向的处理方式,增强了模型对长时依赖

的建模能力,从而进一步提升了模型的分类性能。综上所述,BiMamba-RMSF模型通过有效的特征提取和时序建模,成功提高了心电信号分类任务的精度与稳定性,展现了其在实际应用中的优势。

4.2 消融实验结果

为进一步验证BiMamba-RMSF的有效性,本文对模型的主要模块BiMamba进行了消融实验。设计并比较了一下3种模型。(1)RMSF-ECG:通过移除BiMamba-RMSF中的BiMamba模块,将原本输入到BiMamba模块的特征进行全局平均池化操作后,输入到分类器中进行模型预测,以此分析BiMamba模块对模型的作用,记为“RMSF-ECG”。(2)Mamba-ECG:通过将BiMamba-RMSF中的BiMamba模块替换为Mamba模块,即仅使用单向Mamba变换来进行时序建模,以此验证双向Mamba变换的有效性,记为“Mamba-ECG”。(3)BiMamba-RMSF:在RMSF-ECG的基础上加入BiMamba模块,即为本文提出的模型。消融实验各模型在测试集上的平均评估指标如表4所示。

表4 消融实验结果 ( $\bar{x}\pm s, \%$ )

Table 4 Results of ablation study ( $Mean\pm SD, \%$ )

模型	准确率	AUC	精确率	召回率	F1 分数
RMSF-ECG	88.69±0.26	93.44±0.06	83.76±0.62	64.51±2.03	72.23±1.38
Mamba-ECG	89.27±0.24	93.20±0.27	83.70±1.33	63.06±2.59	70.62±1.76
BiMamba-RMSF	89.42±0.18	93.56±0.19	83.95±1.04	65.56±1.93	72.85±1.06

对消融实验结果进行分析,首先可以发现,RMSF-ECG模型尽管通过去除BiMamba模块,仅保留全局平均池化和分类器,但其平均精确率和平均召回率分别为83.76%和64.51%,这两项指标低于BiMamba-RMSF模型。这种性能差距表明,BiMamba模块在提升模型对异常类别的识别能力和综合判别能力方面起到了一定的积极作用。特别是在处理不平衡数据时,召回率的提升表明BiMamba模块有助于增强模型对正类(即较少见的类别)心电信号的敏感性,从而有效提高模型的全面性能。

Mamba-ECG模型将BiMamba模块替换为单向

Mamba模块,其平均准确率为89.27%,虽然相较于RMSF-ECG有所提升,但仍低于BiMamba-RMSF的89.42%。这一结果进一步验证了双向Mamba模块在建模长时依赖关系时的重要性。通过引入双向信息流,BiMamba-RMSF能够同时捕捉到正向和反向的时序依赖,显著提高了模型的时序建模能力,从而提高了精确率(83.95%)和召回率(65.56%)。相比之下,Mamba-ECG模型虽然在精确率上表现较好(83.70%),但召回率较低(63.06%),这表明模型在分类时较为谨慎,偏向于减少假正例的产生,从而可能导致较高的假阴性率,即漏掉更多的正类样本。因



此, 单向 Mamba 模块在时序建模方面的能力有限, 导致模型在召回能力上的表现不如 BiMamba 模块。

综上所述, 消融实验表明, BiMamba 模块对提高模型的分类性能, 尤其是在不平衡数据处理和时序建模方面, 具有积极意义。该模块在增强时序依赖建模的同时, 有效提升了模型的精确度和召回能力, 从而更好地完成 12 导联多标签心电信号分类任务。

## 5 总结

本文提出的基于 RMSF 和 BiMamba 的心电自动诊断模型 BiMamba-RMSF, 显著提升了模型对 12 导联心电信号的时序特征学习能力。通过引入双向 Mamba 模块与 RMSF, 本模型能够有效捕捉和利用心电信号中的长时依赖关系并提取更丰富的时序特征, 从而提高了模型在心电诊断任务中的准确性和鲁棒性。对比实验与消融实验结果表明, BiMamba-RMSF 在心电信号分类任务中表现出色, 尤其在精确率和召回率等关键指标上均有所提升。

尽管本研究已在提高心电信号分类性能方面取得了良好成果, 但仍有一些方面值得进一步探索和优化。未来的工作可以从以下几个方向展开: 首先, 考虑引入更多的时序建模技术, 如 Transformer 等自注意力机制, 以进一步增强模型在复杂时序模式下的学习能力; 其次, 研究不同信号采样率和噪声干扰下模型的鲁棒性, 提升其在实际应用中的适应性; 最后, 探索模型在多种心电信号自动检测任务中的应用, 包括小样本类别上的性能表现, 以进一步验证其在临床实践中的潜力。通过不断优化模型结构和增强其泛化能力, 期望能够为心电自动诊断模型的实际应用提供更加可靠的技术支持。

## 【参考文献】

- [1] World Health Organization. Cardiovascular diseases (CVDs)[EB/OL]. (2021-06-11)[2021-12-26]. [https://www.who.int/news-room/fact-sheets/detail/cardiovascular-diseases-\(cvds\)](https://www.who.int/news-room/fact-sheets/detail/cardiovascular-diseases-(cvds)).
- [2] Kaplan Berkaya S, Uysal AK, Sora Gunal E, et al. A survey on ECG analysis[J]. Biomed Signal Process Control, 2018, 43: 216-235.
- [3] Saadatnejad S, Oveisi M, Hashemi M. LSTM-based ECG classification for continuous monitoring on personal wearable devices[J]. IEEE J Biomed Health Inform, 2020, 24(2): 515-523.
- [4] Liu XW, Wang H, Li ZJ, et al. Deep learning in ECG diagnosis: a review[J]. Knowl Based Syst, 2021, 227: 107187.
- [5] Ahmed AA, Ali W, Abdullah TA, et al. Classifying cardiac arrhythmia from ECG signal using 1D CNN deep learning model[J]. Mathematics, 2023, 11(3): 562.
- [6] Pandey SK, Shukla A, Bhatia S, et al. Detection of arrhythmia heartbeats from ECG signal using wavelet transform-based CNN model[J]. Int J Comput Intell Syst, 2023, 16(1): 80.
- [7] Hannun AY, Rajpurkar P, Haghpahani M, et al. Cardiologist-level arrhythmia detection and classification in ambulatory electrocardiograms using a deep neural network[J]. Nat Med, 2019, 25(1): 65-69.
- [8] 庞伟, 马乐荣, 何进荣, 等. 融合 VGG16 和 TextCNN 的心电信号智能诊断模型[J]. 延安大学学报(自然科学版), 2022, 41(4): 97-102.
- [9] Pang W, Ma LR, He JR, et al. Intelligent diagnostic model of ECG signal integrating VGG16 and TextCNN[J]. Journal of Yan'an University(Natural Science Edition), 2022, 41(4): 97-102.
- [9] Coppola E, Savardi M, Massussi M, et al. HuBERT-ECG: a self-supervised foundation model for broad and scalable cardiac applications[J/OL]. medRxiv. (2024-11-18). <https://doi.org/10.1101/2024.11.14.24317328>.
- [10] Bui NT, Hoang DH, Phan T, et al. TSRNET: simple framework for real-time ECG anomaly detection with multimodal time and spectrogram restoration network[C]//2024 IEEE International Symposium on Biomedical Imaging (ISBI). Piscataway, NJ, USA: IEEE, 2024: 1-4.
- [11] Kim S. Learning general representation of 12-lead electrocardiogram with a joint-embedding predictive architecture[EB/OL]. (2024-12-03). <https://arxiv.org/abs/2410.08559>.
- [12] Gu A, Dao T. Mamba: linear-time sequence modeling with selective state spaces[EB/OL]. (2024-05-31). <https://arxiv.org/abs/2312.00752>.
- [13] Liang AB, Jiang XG, Sun Y, et al. Bi-Mamba+: bidirectional mamba for time series forecasting[EB/OL]. (2024-06-27). <https://arxiv.org/abs/2404.15772>.
- [14] Wagner P, Strodthoff N, Bousseljot RD, et al. PTB-XL, a large publicly available electrocardiography dataset[J]. Sci Data, 2020, 7(1): 154.
- [15] Wagner P, Strodthoff N, Bousseljot RD, et al. PTB-XL, a large publicly available electrocardiography dataset: version: 1.0.3[EB/OL]. (2022-11-09). <https://physionet.org/content/ptb-xl/1.0.3/>.
- [16] Goldberger AL, Amaral LA, Glass L, et al. PhysioBank, PhysioToolkit, and PhysioNet: components of a new research resource for complex physiologic signals[J]. Circulation, 2000, 101(23): E215-E220.
- [17] ISO. Health informatics-standard communication protocol: part 91064: computer-assisted electrocardiography: ISO 11073-91064: 2009[S]. Vernier, Geneva, Switzerland: ISO, 2009.
- [18] Gu A, Johnson I, Goel K, et al. Combining recurrent, convolutional, and continuous-time models with linear state-space layers[C]//Proceedings of the 35th International Conference on Neural Information Processing Systems. Red Hook, NY, USA: Curran Associates Inc., 2021: 572-585.
- [19] Wang C, Tsepa O, Ma J, et al. Graph-mamba: towards long-range graph sequence modeling with selective state spaces[EB/OL]. (2024-02-01). <https://arxiv.org/abs/2402.00789>.
- [20] Fu DY, Dao T, Saab KK, et al. Hungry hungry hippos: towards language modeling with state space models[EB/OL]. (2023-04-29). <https://arxiv.org/abs/2212.14052>.
- [21] He T, Zhang Z, Zhang H, et al. Bag of tricks for image classification with convolutional neural networks[C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ, USA: IEEE, 2019: 558-567.
- [22] Ismail Fawaz H, Lucas B, Forestier G, et al. InceptionTime: finding AlexNet for time series classification[J]. Data Min Knowl Discov, 2020, 34(6): 1936-1962.
- [23] Hwang S, Cha J, Heo J, et al. Multi-label abnormality classification from 12-lead ECG using a 2D residual U-Net[C]//ICASSP 2024 - 2024 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). Piscataway, NJ, USA: IEEE, 2024: 2265-2269.
- [24] Hwang S, Cha J, Heo J, et al. Multi-label ECG abnormality classification using a combined ResNet-DenseNet architecture with ResU blocks[C]//2023 IEEE EMBS Special Topic Conference on Data Science and Engineering in Healthcare, Medicine and Biology. Piscataway, NJ, USA: IEEE, 2023: 111-112.

(编辑: 薛泽玲)