

DOI: 10.19650/j.cnki.cjsi.J2312031

# 使用异质集成学习和心电信号异构特征融合的 睡眠呼吸暂停分类方法

韩亮<sup>1,2</sup>, 罗统军<sup>1</sup>, 蒲秀娟<sup>1,2</sup>, 刘媛<sup>1</sup>, 梁国祥<sup>1</sup>

(1. 重庆大学微电子与通信工程学院 重庆 400044; 2. 生物感知与智能信息处理重庆市重点实验室 重庆 400044)

**摘要:**睡眠呼吸暂停(SA)会影响睡眠质量,增加心脑血管疾病风险,其准确分类有助于在SA早期阶段及时开展针对性治疗。本文提出一种使用异质集成学习和异构特征融合的SA分类新方法。首先从原始心电信号中提取小波时频谱,使用SE-ResNet作为初级分类器;然后提取RR间期序列和R峰值序列,使用1D CNN-LSTM作为初级分类器;再提取心率变异性特征,使用SVM作为初级分类器。最后采用堆叠法作为异质集成学习的融合策略,再使用另一个SVM作为次级分类器实现SA分类。在Apnea-ECG数据集上进行实验,所提出的SA分类方法的准确率为89.12%。实验结果表明,所提方法有效利用了各初级分类器的多样性和异构特征的互补性,其性能优于传统的SA分类方法。

**关键词:**睡眠呼吸暂停;集成学习;异构特征融合;心电信号;深度学习

中图分类号: TH701 TP391 文献标识码: A 国家标准学科分类代码: 510.4010

## Sleep apnea classification method utilizing heterogeneous ensemble learning and electrocardiogram heterogeneous feature fusion

Han Liang<sup>1,2</sup>, Luo Tongjun<sup>1</sup>, Pu Xiujuan<sup>1,2</sup>, Liu Yuan<sup>1</sup>, Liang Guoxiang<sup>1</sup>

(1. School of Microelectronics and Communication Engineering, Chongqing University, Chongqing 400044, China;

2. Chongqing Key Laboratory of Bio-perception & Intelligent Information Processing, Chongqing 400044, China)

**Abstract:** Sleep apnea (SA) affects the quality of sleep and increases the risk of cerebrovascular and cardiovascular diseases. It is advantageous to implement the accurate classification for the timely treatment at the early stage of SA. In this paper, one novel SA classification method utilizing heterogeneous ensemble learning and heterogeneous feature fusion is proposed. Firstly, the SE-ResNet is used as primary classifier of the extracted wavelet time-frequency spectrum from raw electrocardiogram (ECG). Then the 1D CNN-LSTM is used as primary classifier of the extracted R-peak to R-peak interval (RRI) sequence and R-peak amplitude (RAMP) sequence. And the SVM is used as primary classifier of extracted heart rate variability features. Finally, the stacking method is adopted as fusion strategy for heterogeneous ensemble learning, and then another SVM is used as the secondary classifier to implement SA classification. The proposed SA classification method is evaluated on Apnea-ECG dataset, whose accuracy is 89.12%. Experimental results show that the proposed method utilizes the diversity of primary classifiers and complementarity of heterogeneous features efficiently, which outperforms the conventional SA classification method.

**Keywords:** sleep apnea (SA); ensemble learning; heterogeneous feature fusion; electrocardiogram (ECG); deep learning

## 0 引言

睡眠呼吸暂停 (sleep apnea, SA) 患者会在夜间睡眠时出现呼吸无意识暂停或呼吸减弱<sup>[1]</sup>。临床研究表明,

SA 会导致心律失常、高血压等心脑血管疾病,其早期诊断有利于及时开展针对性治疗,预防患者出现严重健康问题。目前临床诊断 SA 的主要方法是多导睡眠图 (polysomnography, PSG)。PSG 采集需要专门实验室和特殊设备,还必须由专业医生监测采集过程和人工分

析<sup>[2]</sup>。PSG 采集过程复杂且昂贵,难以成为 SA 的常规监测方式<sup>[3]</sup>。现有研究成果表明,SA 会破坏交感和副交感神经系统之间的平衡,心电信号 (electrocardiogram, ECG) 能有效反映两者活动状况<sup>[4]</sup>,成本低且易于采集。从 ECG 中提取各种特征进行 SA 自动分类能够降低医生工作强度,对 SA 早期诊断具有极为重要的意义。

传统的使用 ECG 的 SA 自动分类方法主要包括特征提取和分类模型两部分。目前,时频分析、小波变换、心率变异性 (heart rate variability, HRV) 分析等方法均已被成功地应用于 ECG 特征提取<sup>[5]</sup>;常用分类模型包括 KNN、LR、SVM 等<sup>[6]</sup>。基于传统机器学习的 SA 自动分类方法时间复杂度低、特征可解释性好且生理学意义明确,但其分类结果依赖于从 ECG 中手工提取特征。深度学习具有从 ECG 自学习有用特征的能力,能描述更复杂的高维特征。长短期记忆网络 (LSTM)<sup>[4]</sup>、卷积神经网络 (CNN)<sup>[7]</sup>、LSTM 结合循环神经网络 (RNN)<sup>[8]</sup>、LetNet-5 网络<sup>[9]</sup>、1D-ResNet 网络<sup>[10]</sup> 等深度学习方法已被成功地应用于 SA 自动分类。

异构特征融合方法能够综合利用多种特征的信息,实现其优势互补。异质集成学习方法使用不同种类的初级分类器实现集成学习,其分类性能明显优于单个初级分类器。为此,本文提出一种使用异质集成学习和 ECG 异构特征融合的 SA 分类新方法。首先分别从原始 ECG 中提取小波时频谱、RR 间期 (R-peak to R-peak interval, RRI) 序列、R 峰值 (R-peak amplitude, RAMP) 序列和 HRV 特征;然后分别使用 SE-ResNet、1D CNN-LSTM 和 SVM 作为初级分类器;最后使用堆叠法在决策层面进行特征融合并实现 SA 分类。

### 1 使用集成学习和特征融合的 SA 分类方法

ECG 能有效反映 SA 事件<sup>[4]</sup>,多特征融合能更充分地利用 ECG 的各种信息,有效提高 SA 分类性能。针对 ECG 数据,本文提出一种使用异质集成学习和 ECG 异构特征融合的 SA 分类新方法,如图 1 所示。

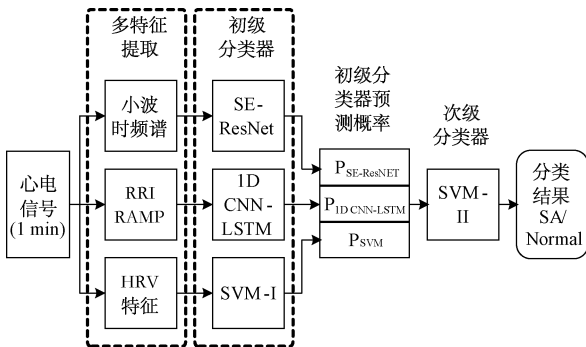


图 1 本文提出的 SA 分类方法

Fig. 1 The proposed SA classification method

#### 1.1 多特征提取与初级分类器设计

##### 1) 结合小波时频谱与 SE-ResNet 的 SA 分类

将一维时间序列转换为二维图像表示,能够将时间序列内部结构可视化,从而更好地反映原始信号中潜在特征;进而结合深度学习实现分类,其性能优于传统一维时间序列分类方法<sup>[11]</sup>。SA 事件发生时,ECG 的瞬时频率会出现变化。小波变换具有良好时频局域化特性,能获得不同尺度下 ECG 的高频和低频信息。本文使用连续小波变换获取 ECG 小波时频谱,小波时频谱将 ECG 时频域局部特征以能量变化规律呈现。本论文进而结合 CNN、残差结构和注意力机制,构建 SE-ResNet 作为初级分类器,其网络结构如图 2 所示。

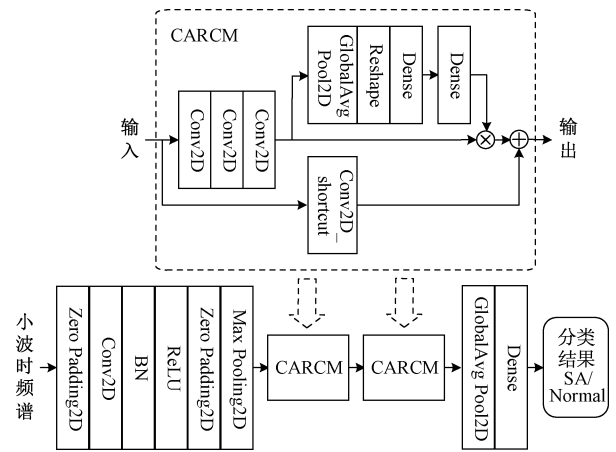


图 2 SE-ResNet 网络结构

Fig. 2 The network structure of SE-ResNet

如图 2 所示,将 ECG 小波时频谱经过零填充层、卷积层、BN (batch normalization) 层、ReLU 层、另一个零填充层和最大池化层,可获取多通道小波时频谱特征表示,但却难以区分每个通道的有效信息和冗余信息。注意力机制对信息按重要程度分配权值,更关注关键特征。为此,本文基于 SE (squeeze and excitation)<sup>[12]</sup> 模块,设计通道注意力残差卷积模块 (channel attention residual convolution module, CARCM),以选择关键通道信息。如图 2 中 CARCM 模块所示,挤压 (squeeze) 函数通过 GlobalAvgPool2D 层实现,然后经过 Reshape 层与两个激活函数分别为 ReLU 和 Sigmoid 的全连接 (Dense) 层计算得到通道权重,最后将自适应加权后的特征向量与 Conv2D\_shortcut 层提取的特征向量相加构成跨模块连接的残差结构。经两个堆叠的 CARCM 模块得到  $32 \times 32 \times 16$  大小的深度特征表示,再经过 1 个全局平均池化层和 1 个激活函数为 Softmax 的 Dense 层,输出 SA 分类结果。SE-ResNet 网络模型参数如表 1 所示。

##### 2) 结合 RRI-RAMP 序列与 1D CNN-LSTM 的 SA 分类

直接使用原始 ECG 进行 SA 分类需将长片段 ECG

表1 SE-ResNet 网络模型参数

Table 1 The model parameters of SE-ResNet

层类型	输出尺寸	通道数量	核大小以及步长大小等
InputLayer	128×128	1	-
ZeroPadding2D	134×134	1	padding=((3, 3), (3, 3))
Conv2D	64×64	64	filters=64, kernel_size=7, strides=2
BN	64×64	64	-
ReLU	64×64	64	-
ZeroPadding2D	66×66	64	padding=((1, 1), (1, 1))
MaxPooling2D	32×32	64	Kernel_size=3, strides=2
CARCM	32×32	16	-
CARCM	32×32	16	-
GlobalAvgPool2D	16	-	-
Output	2	-	units=2, activation='softmax'

作为深度学习模型输入数据,数据量大且QRS波群结构相似,容易导致模型收敛困难或拟合度低。RRI序列和RAMP序列能更好反映心率变化规律,数据量小且对SA事件敏感。为此,本文从原始ECG中提取RRI序列和RAMP序列,经相同频率重采样后组合为双通道RRI-RAMP序列。CNN能有效提取ECG具有平移、缩放和旋转不变性的高级特征;LSTM具有长期记忆特性,非常适合序列建模。本文构建1D CNN-LSTM作为初级分类器,网络结构和模型参数分别如图3和表2所示。




图3 1D CNN-LSTM 网络结构

Fig.3 The network structure of 1D CNN-LSTM

表2 1D CNN-LSTM 网络模型参数

Table 2 The model parameters of 1D CNN-LSTM

层类型	输出尺寸	通道数量	核大小以及步长大小等
InputLayer	180	2	-
Conv1D	180	32	filters=32, kernel_size=3, strides=1
MaxPooling	60	32	pool_size=3
Conv1D	60	64	filters=64, kernel_size=5, strides=1
MaxPooling	20	64	pool_size=3
Dropout	20	64	Dropout_rate=0.2
Reshape	10	128	-
LSTM	16	-	units=16, activation='tanh'
Dense	32	-	units=32
Output	2	-	units=2, activation='softmax'

3) 结合 HRV 特征与 SVM 的 SA 分类

HRV 指相邻心动周期之间时间上的微小差异。HRV 时域特征指对 RRI 序列信号进行统计分析得到的参数。HRV 频域特征指对 RRI 序列信号进行功率谱密度分析并计算不同频段分量的能量。HRV 非线性域特征指对 RRI 序列信号进行非线性分析,最常见的非线性域特征是由庞加莱图计算得到,包括庞加莱图椭圆短轴(SD<sub>1</sub>)、庞加莱图椭圆长轴(SD<sub>2</sub>)和 SD<sub>1</sub>/SD<sub>2</sub>。本文使用的 HRV 特征如表3所示,选择 SVM 作为初级分类器。

表3 HRV 特征

Table 3 HRV features

序号	特征标签	特征描述
1	MRRI	RR 间期均值
2	MHR	瞬时心率均值
3	SDRR	RR 间期标准差
4	RMSSD	相邻 RR 间隔之间差值的均方根
5	NN50	相邻 RR 间期超过 50 ms 的数量
6	PNN50	相邻 RR 间期超过 50 ms 的数量除以 RR 间期数量
7	VLF	极低频率(0~0.04 Hz)分量的功率
8	VLF/total	极低频率(0~0.04 Hz)分量的功率占比
9	LF	低频率(0.04~0.15 Hz)分量的功率
10	LF/total	低频率(0.04~0.15 Hz)分量的功率占比
11	HF	高频率(0.15~0.4 Hz)分量的功率
12	HF/total	高频率(0.15~0.4 Hz)分量的功率占比
13	SD <sub>1</sub>	庞加莱图椭圆短轴
14	SD <sub>2</sub>	庞加莱图椭圆长轴
15	SD <sub>1</sub> /SD <sub>2</sub>	SD <sub>1</sub> 和 SD <sub>2</sub> 两者之比

1.2 基于 SVM 融合的异质集成学习

本文提出的基于 SVM 融合的异质集成分类器,如图1所示。集成多样性指所使用的初级分类器之间的差异,初级分类器多样性越高,集成学习性能越好。本文使用 SE-ResNet、1D CNN-LSTM 和 SVM 作为初级分类器,其结构和学习能力均不相同,具有较高的多样性,有利于提高 SA 分类性能。本文使用堆叠法<sup>[13]</sup>作为融合策略,选择泛化性强的 SVM 作为次级分类器。首先使用初始数据集分别训练各初级分类器;然后将各初级分类器输出的预测概率和初始数据对应的真实标签组合成一个新的数据集;再以各初级分类器输出的预测概率作为次级分类器的输入,以初始数据的标签作为样本标签,训练次级分类器,最终实现 SA 分类。

1.3 SA 分类方法具体步骤

1) 训练初级分类器 SE-ResNet

采用 1.1 节中结合小波时频谱与 SE-ResNet 的 SA 分类所述方法,使用原始 ECG 的小波时频谱作为原始训练集数据,训练 SE-ResNet;再次将小波时频谱输入到训练好的 SE-ResNet 分类器,得到初级分类器 SE-ResNet 输出的预测概率  $P_{SE-ResNet}$ 。

### 2) 训练初级分类器 1D CNN-LSTM

使用 QRS 检测算法<sup>[14]</sup>检测原始 ECG 的 R 峰位置,进而计算 RRI 序列和 RAMP 序列,使用 3 次样条插值算法将其重采样至 3 Hz 后组合为双通道 RRI-RAMP 序列。采用 1.1 节中结合 RRI-RAMP 序列与 1D CNN-LSTM 的 SA 分类所述方法,使用该序列作为原始训练集数据,训练 1D CNN-LSTM;再次将双通道 RRI-RAMP 序列输入到训练好的 1D CNN-LSTM 分类器,得到初级分类器 1D CNN-LSTM 输出的预测概率  $P_{1D CNN-LSTM}$ 。

### 3) 训练初级分类器 SVM-I

采用 1.1 节中结合 HRV 特征与 SVM 的 SA 分类所述方法,使用 HRV 特征作为原始训练集数据,训练 SVM-I;再次将 HRV 特征输入到训练好的 SVM-I 分类器,得到初级分类器 SVM-I 输出的预测概率  $P_{SVM}$ 。

### 4) 构建基于 SVM 融合的异质集成分类器

采用 1.2 节所述方法,将各个初级分类器的预测概率  $P_{SE-ResNet}$ 、 $P_{1D CNN-LSTM}$ 、 $P_{SVM}$  和原始 ECG 片段对应的真实标签组合成新的训练集数据,训练次级分类器 SVM-II;然后将训练好的初级分类器 SE-ResNet、1D CNN-LSTM、SVM-I 和次级分类器 SVM-II 按照图 1 所示的方式组合,构建基于 SVM 融合的异质集成分类器。

### 5) SA 分类

对于待测试的 ECG,首先采用 1.1 节所述方法分别提取其小波时频谱、RRI 序列、RAMP 序列和 HRV 特征,然后再将提取的特征输入到经由步骤 1)~4) 构建的基于 SVM 融合的异质集成分类器,实现 SA 分类。

## 2 实验结果与分析

### 2.1 实验数据及其预处理

Apnea-ECG 数据集<sup>[15]</sup>包含 70 条单导联 ECG 记录,被分为 2 组,其中一组用于辅助诊断 SA 算法研究,将其作为训练集数据;另一组用于算法性能评估,将其作为测试集数据。首先采用 Varanini 等<sup>[14]</sup>提出的方法抑制原始 ECG 中的基线漂移等噪声,再根据 Apnea-ECG 数据集的 SA 事件标注信息,将去噪后 ECG 分割为若干个 1 min 的 ECG 片段。实验数据信息统计如表 4 所示。

### 2.2 性能评价方法

#### 1) 分类性能评价指标

本文采用准确率 (ACC)、精确率 (PRE)、召回率

表 4 Apnea-ECG 数据集实验数据

Table 4 The experiment data based on Apnea-ECG database

实验数据	记录个数		片段个数(片段时长 1 min)		
	SA 患者	正常	A(发生呼吸暂停事件)	N(正常)	合计
训练集	23	12	6 473	10 236	16 709
测试集	23	12	6 490	10 455	16 945
合计	46	24	12 963	20 691	33 654

(REC)、 $F_1$  分数和 AUC 评价 SA 分类方法的分类性能<sup>[6]</sup>。

#### 2) 临床诊断评价指标

在临床上,医生通过计算 AHI 指数 (apnea-hypopnea index) 来进行诊断<sup>[10]</sup>。AHI 指数的计算方法如下:

$$AHI = \left(\frac{60}{T}\right) \times Total(SA) \quad (1)$$

式中:  $T$  表示每个 ECG 记录的长度 (单位为 min);  $Total(SA)$  表示该记录中分类器检测出的 SA 片段数量。

AHI  $\geq 5$  的受试者被归类为 SA 患者。常用 MAE (mean absolute error) 指标衡量分类器计算的 AHI 值与实际 AHI 值之间的误差<sup>[10]</sup>。MAE 的计算方法如下:

$$MAE = \frac{1}{N} \sum_{i=1}^N |Estimated_{AHI}^i - Real_{AHI}^i| \quad (2)$$

式中:  $N$  表示 ECG 记录的数量;  $Estimated_{AHI}^i$  表示第  $i$  个 ECG 记录由分类器分类结果计算出来的 AHI 指数;  $Real_{AHI}^i$  表示第  $i$  个 ECG 记录实际的 AHI 指数。

### 2.3 本文方法实验结果与分析

本文所有实验采用的计算机 CPU 为 Intel E5-4650 v3@2.10 GHz 处理器,内存为 32 GB,显卡为 NVIDIA GeForce GTX 1070Ti,操作系统为 Windows 10,编程工具为 Python 3.6 和 MATLAB R2019a,深度学习框架为 TensorFlow2.4,机器学习库为 Scikit-Learn 和 Keras。在本文中,所有实验均使用如 2.1 节所述 Apnea-ECG 数据集。本文使用的初级分类器 SVM-I 和次级分类器 SVM-II 的参数设置相同,惩罚系数  $C=1.0$ ,核函数选择“rbf”,其余参数选择默认值。

#### 1) 多特征提取与初级分类器实验结果与分析

采用如 1.1 节所述“多特征提取与初级分类器设计”方法进行实验,具体包括:

(1) 方法 1:首先使用连续小波变换获取 ECG 的小波时频谱,小波基为双正交小波“bior4.4”,尺度范围为 128 级。进而使用 SE-ResNet 进行 SA 分类。

(2) 方法 2:首先计算 ECG 的 RRI 序列和 RAMP 序列,对两个序列使用 3 次样条插值将其重采样为 3 Hz,然后将其组合成尺寸大小为  $2 \times 180$  的双通道 RRI-RAMP 序列,再使用 1D CNN-LSTM 进行 SA 分类。



(3)方法3:首先提取如表3所示的ECG的15个HRV特征。其中,频域特征通过韦尔奇法(Welch's method)计算HRV信号的功率谱密度得到,非线性域特征通过分析ECG的庞加莱图获得。进而使用SVM进行分类。

实验结果如表5所示。

表5 多特征提取与初级分类器实验结果

Table 5 Experiment results of multi-feature extraction and primary classifier

方法	ACC/%	PRE/%	REC/%	$F_1$	AUC
1	85.23	89.82	77.65	0.832 9	0.814 2
2	86.23	85.31	87.52	0.864 0	0.877 7
3	75.72	82.32	64.91	0.725 8	0.737 2

由表5可知,本文提出的3种特征提取及其对应的初级分类器均能有效地进行SA分类。

2) 异质集成学习与异构特征融合消融实验

首先分别采用1.1节中所述“结合小波时频谱与SE-ResNet的SA分类”方法I、“结合RRI-RAMP序列与1D CNN-LSTM的SA分类”方法II和“结合HRV特征与SVM的SA分类”方法III进行SA分类实验;然后再将方法I、II和III两两结合,使用堆叠法(Stacking)作为融合策略,进行SA分类实验;最后将方法I、方法II和方法III结合,采用如1.3节所述“SA分类方法具体步骤”进行SA分类实验。实验结果如表6所示。

表6 消融实验结果

Table 6 Results of ablation experiment

组合方式	集成策略	ACC/%	PRE/%	REC/%	$F_1$	AUC
I	-	85.23	89.82	77.65	0.832 9	0.814 2
II	-	86.23	85.31	<b>87.52</b>	0.864 0	0.877 7
III	-	75.72	82.32	64.91	0.725 8	0.737 2
I + II	Stacking	88.10	91.18	83.52	0.871 8	0.855 2
I + III	Stacking	85.62	91.69	74.68	0.823 2	0.832 3
II + III	Stacking	87.83	90.56	83.31	0.867 8	0.879 1
I + II + III	Stacking	<b>89.12</b>	<b>92.39</b>	83.87	<b>0.879 2</b>	<b>0.883 5</b>

由表6可知:(1)单独使用方法I、II和III进行SA分类实验,方法II的ACC、REC、 $F_1$ 分数和AUC均高于方法I和III,方法II性能最优。(2)方法I、II和III两两组合,采用堆叠法作为融合策略进行SA分类,方法I和II两两组合的分类性能优于其他两种组合方法,也优于单独使用方法I、II和III进行SA分类。(3)方法I、II和III结合,采用堆叠法作为融合策略进行SA分类,其ACC、PRE和AUC均为最高。但其REC稍低于方法II,这是由于方法I和III的REC远低于方法II,因此将3种

方法结合,其REC反而有所下降。但是,本文提出的方法的 $F_1$ 分数最高,这说明综合考虑PRE和REC时,3种方法相结合性能更好。

综上所述,本文使用的异质集成学习和异构特征融合方法成功实现了心电信号的小波时频谱、RRI序列、RAMP序列和HRV多种特征的优势互补,且充分利用了SE-ResNet、1D CNN-LSTM和SVM3种初级分类器的多样性,有效地提高了SA分类性能。

3) 异质集成学习的融合策略对比实验结果与分析

将如2.3节中异质集成学习与异构特征融合消融实验所述方法I、II和III两两结合,以及三者相结合,再分别使用投票法、平均法和堆叠法(Stacking)作为异质集成学习的融合策略,实验结果如图4所示。

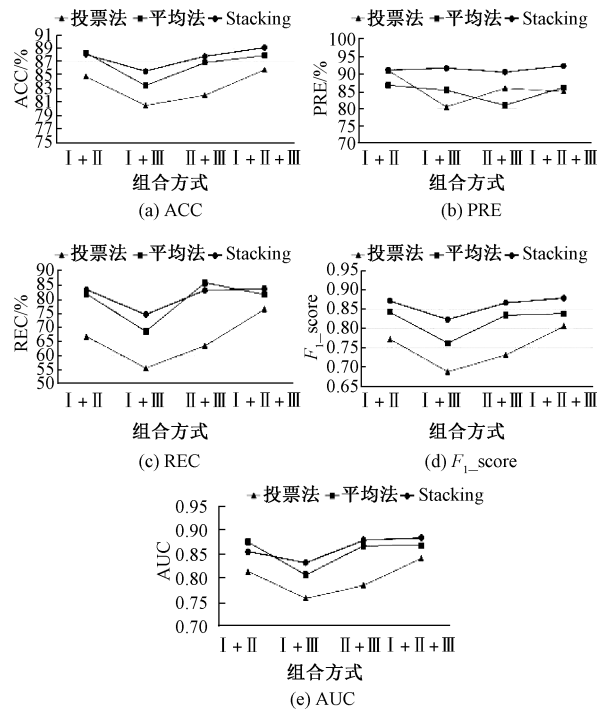


图4 不同融合策略实验结果

Fig. 4 Experiment results of different fusion strategies

由图4可知:(1)方法I、II和III三者结合,采用堆叠法作为融合策略,其ACC、PRE、 $F_1$ 分数和AUC优于投票法和平均法;也优于3种方法两两结合且分别采用投票法、平均法和堆叠法融合策略的SA分类方法。(2)方法I、II和III三者结合,采用堆叠法作为融合策略,其REC稍低于方法II和III结合且采用平均法作为融合策略的SA分类方法,但是其 $F_1$ 分数明显高于后者,AUC也相对于后者更高,在总体上具有更好的分类性能。

综上所述,方法I、II和III三者结合,采用堆叠法作为异质集成学习的融合策略,与投票法和平均法相比具有更好的鲁棒性和分类性能。

2.4 对比实验结果与分析

为进一步验证本文提出的 SA 分类方法,针对 Apnea-ECG 数据集,选取近年来具有代表性的使用 ECG 数据进行 SA 分类的深度学习算法进行对比实验,具体包括:结合 RRI-RAMP 序列和 LSTM-RNN 网络<sup>[8]</sup>的 SA 分类方法;结合 RRI-RAMP 序列和 LeNet-5 网络<sup>[9]</sup>的 SA 分类方法;结合 RRI-RAMP 序列和 1D-ResNet 网络<sup>[10]</sup>的 SA 分类方法。实验结果如表 7 所示。

表 7 SA 分类方法性能对比

Table 7 Performance comparison of SA classification methods

分类器	ACC /%	PRE /%	REC /%	$F_1$	AUC
LSTM-RNN <sup>[8]</sup>	86.10	85.14	<b>86.42</b>	0.857 7	0.857 0
LeNet-5 <sup>[9]</sup>	80.37	79.20	79.68	0.794 3	0.796 9
1D-ResNet <sup>[10]</sup>	84.04	84.04	81.77	0.828 8	0.817 7
本文方法	<b>89.12</b>	<b>92.39</b>	83.87	<b>0.879 2</b>	<b>0.883 5</b>

由表 7 可知:(1) 本文提出的 SA 分类方法的 ACC、PRE、 $F_1$  分数和 AUC 分别为 89.12%、92.39%、0.879 2 和 0.883 5,比基于 LSTM-RNN<sup>[8]</sup>、LeNet-5<sup>[9]</sup>、1D-ResNet<sup>[10]</sup>的 3 种 SA 分类方法分别平均提升了 5.62%、9.60%、0.052 3 和 0.059 6。本文所提出的 SA 分类方法的性能明显优于其他 3 种近年来具有代表性的针对 ECG 数据进行 SA 分类的深度学习算法。(2) 本文提出的 SA 分类方法的 REC 稍低于基于 LSTM-RNN 的 SA 分类方法,但是,本文方法的  $F_1$  分数最高,其 AUC 也为最高,这说明综合考虑 PRE 和 REC 时,本文方法优于基于 LSTM-RNN 的 SA 分类方法。

为更充分地验证本文提出的 SA 分类方法的适用性,进一步针对 Goldberger 等<sup>[16]</sup>提供的实际测试数据进行对比实验。该实际测试数据集(UCDDb)包含 25 条三导联 ECG 记录,本论文首先采用与 2.1 节相同的去噪方法抑制原始 ECG 中的噪声,然后依据 UCDDb 数据集中的 SA 事件标注信息将去噪后的 ECG 分割为若干个 1 min 的 ECG 片段。最终实验数据统计信息如表 8 所示。

表 8 UCDDb 数据集实验数据

Table 8 The experiment data in UCDDb database

实验数据	片段个数(片段时长 1 min)		
	A(发生呼吸暂停事件)	N(正常)	合计
训练集	2 005	3 007	5 012
测试集	859	1 289	2 148
合计	2 864	4 296	7 160

采用与针对 Apnea-ECG 数据集的相同的实验方法进行对比实验,实验结果如表 9 所示。

表 9 UCDDb 数据集 SA 分类方法性能对比

Table 9 Performance comparison of SA classification methods with UCDDb database

分类器	ACC /%	PRE /%	REC /%	$F_1$	AUC
LSTM-RNN <sup>[8]</sup>	84.31	78.74	<b>83.24</b>	0.809 3	0.823 5
LeNet-5 <sup>[9]</sup>	78.26	71.08	76.95	0.739 0	0.785 2
1D-ResNet <sup>[10]</sup>	83.01	78.00	80.09	0.790 4	0.802 9
本文方法	<b>86.50</b>	<b>83.75</b>	82.19	<b>0.829 6</b>	<b>0.862 4</b>

由表 9 可知,针对 Goldberger 等<sup>[16]</sup>提供的实际测试数据(UCDDb),采用本文提出的方法的准确率、 $F_1$  分数和 AUC 最高。

综上所述,本文提出的方法的 SA 分类性能最优。

2.5 基于个体的 SA 分类实验结果与分析

为更充分地验证本论文所提出的 SA 分类方法,针对 Apnea-ECG 数据集,进一步进行基于个体的 SA 分类实验。首先采用与 2.3 节中异质集成学习与异构特征融合消融实验相同的方法,对属于同一个受试者的所有 1 min 时长 ECG 片段进行 SA 分类;然后按照 2.2 节所述 AHI 指数公式计算得到每个受试者的 AHI 指数,进而判断该受试者是否患有 SA。实验结果如表 10 所示。

表 10 基于个体的 SA 分类实验结果

Table 10 Experimental results of individual-based SA classification

组合方式	集成策略	ACC/%	PRE/%	REC/%	MAE
I	-	97.14	100.00	95.65	7.41
II	-	97.14	95.83	100.00	4.61
III	-	91.42	88.46	100.00	10.06
I + II	Stacking	97.14	100.00	95.65	4.60
I + III	Stacking	94.28	95.65	95.65	6.62
II + III	Stacking	100.00	100.00	100.00	3.84
I + II + III	Stacking	100.00	100.00	100.00	3.63

注: I 表示结合小波时频谱与 SE-ResNet 的 SA 分类方法; II 表示结合 RRI-RAMP 序列与 1D CNN-LSTM 网络的 SA 分类方法; III 表示结合 HRV 特征与 SVM 的 SA 分类方法。

由表 10 可知:(1) 在基于个体的 SA 分类实验中,单独使用方法 I、II 和 III 均存在误判的情况。(2) 方法 I、II 和 III 两两结合,采用堆叠法(Stacking)作为异质集成学习的融合策略,进行基于个体的 SA 分类,方法 II 和 III 结合的 ACC 达到了 100%;且其预测的 AHI 指数与实际

AHI 指数较为接近, MAE 值较低, 其分类性能优于其它两种组合方法, 也优于单独使用方法 I、II 和 III。(3) 方法 I、II 和 III 结合, 采用堆叠法作为融合策略, 进行基于个体的 SA 分类, 其 ACC 达到了 100%; 且预测的 AHI 指数与实际 AHI 指数最为接近, MAE 值仅为 3.63, 诊断效果最好。

综上所述, 本文提出的方法在基于个体的 SA 分类中也表现出良好的性能。

为更好地评估本论文提出的方法在基于个体的 SA 分类中的性能, 将预测得到 AHI 指数 ( $AHI_{Estim}$ ) 与实际的 AHI 指数 ( $AHI_{Refer}$ ) 进行对比, 结果如图 5 所示。

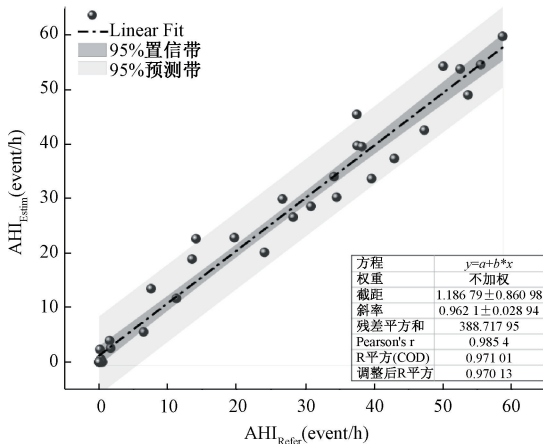


图5 AHI 指数预测的散点图分析

Fig. 5 The analysis of scatter plot for AHI prediction

由图 5 可知, 图中数据点的横、纵坐标分别表示  $AHI_{Refer}$  和  $AHI_{Estim}$ , 所有数据点的拟合直线为  $y = 0.9621x + 1.1867$ , 与理想拟合直线  $y = x$  极为接近, 并且绝大部分数据点分布在 95% 预测带内。此外, 由两组数据计算出来的皮尔逊相关系数 (pearson correlation coefficient, PCCs) 为 0.9854, 这说明通过本文提出的方法计算得到的 35 名受试者的 AHI 指数与其实际 AHI 指数之间存在良好一致性。综上所述, 本文方法在基于个体的 SA 分类与 AHI 指数预测上均表现出较高的性能, 更适用于 SA 分类。

### 3 结 论

本文提出一种用于 SA 分类的基于异质集成学习和 ECG 异构特征融合的方法。实验结果表明: 在基于 ECG 片段的 SA 分类上, 本文方法综合利用了 ECG 的多层次和多类型特征, 以及各初级分类器的多样性, 其性能明显优于基于单特征和单一分类模型的 SA 分类方法, 也优于传统的 SA 分类方法。在基于个体的 SA 分类上, 本文方法也具有较好的性能。

但是, 本文方法的 REC 不是最优的, 因此, 可以进一步探索同时具有较高 REC 和 PRE 的 SA 分类方法, 并将其集成, 以有效提高 SA 分类方法的性能。此外, 睡眠分期与睡眠呼吸暂停检测是评估睡眠质量的关键任务, 多任务学习通过同时学习多个相关任务获取不同任务间的相似性和关联性, 有效提高模型的性能。如何引入多任务学习框架, 同时研究睡眠分期与睡眠呼吸暂停检测, 以更好地全面评估睡眠质量也是本文的下一步研究方向。

### 参考文献

- [1] SHAO SH L, HAN G J, WANG T, et al. Obstructive sleep apnea detection scheme based on manually generated features and parallel heterogeneous deep learning model under IoMT [J]. IEEE Journal of Biomedical and Health Informatics, 2022, 26(12): 5841-5850.
- [2] SHARMA M, KUMBHANI D, YADAW A, et al. Automated Sleep apnea detection using optimal duration-frequency concentrated wavelet-based features of pulse oximetry signals [J]. Applied Intelligence, 2022, 52(2): 1325-1337.
- [3] 王涛, 鲁昌华, 孙怡宁, 等. 多尺度卷积神经网络检测睡眠呼吸暂停 [J]. 电子测量与仪器学报, 2021, 35(7): 30-35.  
WANG T, LU CH H, SUN Y L, et al. Multi-scale convolutional neural network for sleep apnea detection [J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(7): 30-35.
- [4] FAUST O, BARIKA A, SHENFIELD A, et al. Accurate detection of sleep apnea with long short-term memory network based on RR interval signals [J]. Knowledge-Based Systems, 2021, 212(5): 106591.
- [5] MENDONCA F, MOSTAFA S S, RAVELO-GARCIA A G, et al. A review of obstructive sleep apnea detection approaches [J]. IEEE Journal of Biomedical and Health Informatics, 2019, 23(2): 825-837.
- [6] MOHAN S A, AKASH P, RANJANI M. Sleep apnea detection from single-lead ECG: A comprehensive analysis of machine learning and deep learning algorithms [J]. 2023 International Conference on Recent Advances in Electrical, Electronics, Ubiquitous Communication, and Computational Intelligence, 2023: 1-7.
- [7] DEY D, CHAUDHURI S, MUNSHI S. Obstructive sleep apnoea detection using convolutional neural network based deep learning framework [J]. Biomedical Engineering Letters, 2018, 8(1): 95-100.
- [8] PATHINARUPOTHI R K, VINAYKUMAR R, RANGAN E,

- et al. Instantaneous heart rate as a robust feature for sleep apnea severity detection using deep learning[C]. 2017 IEEE-EMBS International Conference on Biomedical and Health Informatics, 2017; 293-296.
- [9] WANG T, LU CH H, SHEN G H, et al. Sleep apnea detection from a single-lead ECG signal with automatic feature-extraction through a modified LeNet-5 convolutional neural network[J]. Peerj, 2019, 7: 7731-7747.
- [10] YANG Q A, ZOU L, WEI K N, et al. Obstructive sleep apnea detection from single-lead electrocardiogram signals using one-dimensional squeeze-and-excitation residual group network[J]. Computers in Biology and Medicine, 2022, 140: 105124.
- [11] WANG ZH G, OATES T. Imaging Time-Series to Improve Classification and Imputation[C]. Proceedings of the Twenty-Fourth International Joint Conference on Artificial Intelligence, 2015; 3939-3945.
- [12] 程德强, 陈杰, 寇旗旗, 等. 融合层次特征和注意力机制的轻量化矿井图像超分辨率重建方法[J]. 仪器仪表学报, 2022, 43(8):73-84.  
CHENG D Q, CHEN J, KOU Q Q, et al. Lightweight super-resolution reconstruction method based on hierarchical features fusion and attention mechanism for mine image[J]. Chinese Journal of Scientific Instrument, 2022, 43(8):73-84.
- [13] NTI I K, ADEKOYA A F, WEYORI B A. A comprehensive evaluation of ensemble learning for stock-market prediction[J]. Journal of Big Data, 2020, 7(1):20.
- [14] VARANINI M, TARTARISCO G, BILLECI L, et al. A multi-step approach for non-invasive fetal ECG analysis[C]. Computing in Cardiology, 2013, 2013: 281-284.
- [15] PENZEL T, MOODY G B, MARK R G, et al. The apnea-ECG database [C]. Computers in Cardiology 2000, 2000:255-258.

- [16] GOLDBERGER A L, AMARAL L A, GLASS L, et al. PhysioBank, PhysioToolkit, and PhysioNet: Components of a new research resource for complex physiologic signals[J]. Circulation, 2000, 101(23):215-220.

## 作者简介



韩亮(通信作者), 分别于1997年、2004年、2008年于重庆大学获得学士学位、硕士学位和博士学位, 2013年7月至2015年7月于美国宾夕法尼亚州立大学磁共振研究中心做访问学者, 现为生物感知与智能信息处理重庆市重点实验室副主任, 重庆大学副教授, 主要研究方向为信号处理和图像处理。

E-mail: hanliangaa@cqu.edu.cn

**Han Liang** (Corresponding author) received his B.Sc., M.Sc. and Ph.D. degrees all from Chongqing University in 1997, 2004 and 2008, respectively. He worked as visiting scholar in NMR research center, Penn State University, USA from July 2013 to July 2015. Now he is the vice director of Chongqing Key Lab of Bio-perception & Intelligent Information Processing and an associate professor in Chongqing University. His main research interest is signal processing and image processing.



罗统军, 2020年于重庆大学获得学士学位, 现为重庆大学微电子与通信工程学院硕士研究生, 主要研究方向为生物医学信号处理。

E-mail: luotongjun@cqu.edu.cn

**Luo Tongjun** received his B.Sc. degree in 2020 from Chongqing University, He is currently a master student in the School of Microelectronics and Communication Engineering at Chongqing University. His main research interest is biomedical signal processing.