

基于瞬时频率与功率谱熵组合特征的心律失常诊断方法

杨启航, 吴思熠, 张卓宇, 陈一鸣

东北大学医学与生物信息工程学院, 辽宁 沈阳
Email: 291042332@qq.com

收稿日期: 2021年2月12日; 录用日期: 2021年3月8日; 发布日期: 2021年3月12日

摘要

心率失常作为最常见的心血管疾病, 威胁着广大人民群众的身体健康。近年来, 通过机器学习对心律失常进行诊断逐渐成为热点, 然而, 当前方法很难在准确率和效率之间取得平衡。为解决这一问题, 本文从实用角度出发, 提出了一种基于瞬时频率与功率谱熵组合特征的心律失常诊断方法, 并使用MIT-BIH心律失常数据库中的心电图数据对该方法进行测试。本文采用Pan-Tompkins算法定位心拍位置以构成数据集, 并利用小波分解对数据进行降噪, 之后将瞬时频率与功率谱熵作为特征, 使用支持向量机(SVM)与双向长短期记忆网络(Bi-LSTM)以测试其性能。最终可得该方法在SVM和Bi-LSTM下的准确率分别为98.3%和99%, 识别速度均在毫秒级, 同时兼顾了效率与正确率, 为应用机器学习的心律失常诊断提供了一种更加优秀的解决方案。

关键词

瞬时频率, 功率谱熵, 心律失常, SVM, Bi-LSTM

An Arrhythmia Diagnosis Method Based on the Combined Feature of Instantaneous Frequency and Power Spectrum Entropy

Qihang Yang, Siyi Wu, Zhuoyu Zhang, Yiming Chen

College of Medicine and Biomedical Information Engineering, Northeastern University, Shenyang Liaoning
Email: 291042332@qq.com

Received: Feb. 12th, 2021; accepted: Mar. 8th, 2021; published: Mar. 12th, 2021

文章引用: 杨启航, 吴思熠, 张卓宇, 陈一鸣. 基于瞬时频率与功率谱熵组合特征的心律失常诊断方法[J]. 计算机科学与应用, 2021, 11(3): 495-504. DOI: 10.12677/csa.2021.113050

Abstract

As the most common cardiovascular disease, arrhythmia is a threat to the health of the public. In recent years, the diagnosis of arrhythmia through machine learning has gradually become a hot spot, however, current methods are difficult to strike a balance between accuracy and efficiency. To solve this problem, an arrhythmia diagnosis model based on instantaneous frequency and power spectrum entropy is proposed by writers, and the ECG data from MIT-BIH arrhythmia database is used to test this model. In this research, the Pan-Tompkins algorithm was used to locate the cardiac beat to form the data set, and wavelet decomposition was used to de-noise the data. Then, the instantaneous frequency and power spectrum entropy were combined as features, and the Support Vector Machine (SVM) and Bidirectional Long Short Term Memory network (Bi-LSTM) were used to test the model performance. Finally, the accuracy of this model respectively is 98.3% and 99% under SVM and Bi-LSTM, and the recognition speed is in millisecond level. Both efficiency and accuracy are good in this method, which provides a more excellent solution for arrhythmia diagnosis using machine learning.

Keywords

Instantaneous Frequency, Power Spectrum Entropy, Arrhythmia, SVM, Bi-LSTM

Copyright © 2021 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

当前, 心血管疾病已然成为中国乃至全球死亡率最高的疾病之一[1] [2], 而心律失常便是最为常见的一类心血管疾病。心律失常的危害在于, 它不但可能加重原有的心脏疾病, 如加快心力衰竭的发展, 而且可以导致患者突然死亡, 严重威胁人类的生命健康[3]。对于心率失常患者来说, 采取有效的诊断方式能使其尽早进行治疗, 有助于提高患者的临床治疗效果[4], 但传统的心律失常诊断多依赖于动态心电图(Holter), 需要由患者携带 Holter 一至三天的时间来进行长时间的心电监测, 不仅影响患者的正常生活, 而且后续数据处理极其繁琐, 大大降低了诊断的效率, 而花费时间较短的 12 导联心电图又易导致心律失常的漏诊[5], 因此, 研究者们一直在寻求一种高效率、高准确率的心律失常诊断方法。

过去 10 年, 许多研究者开始致力于将机器学习应用于包括心律失常在内的心血管疾病的诊断[6]。机器学习可以广义地定义为一种利用数据来提高性能或进行准确预测的计算方法[7], 是人工智能的一个重要分支, 通过机器学习对心电图(ECG)进行分析, 我们可以快速且较为准确的完成心率失常患者的筛查。在以往的实验中, 研究者们通过使用一些典型的机器学习方法, 包括支持向量机(SVM) [8], 决策树[9], 卷积神经网络[10]等, 以较高正确率成功完成了心律失常的诊断, 佐证了机器学习在心律失常诊断中的优越性。然而, 当面对大数据量、大差异性的样本数据时, 上述方法很难在准确率和效率之间取得平衡。

为了同时兼顾准确率与运算速度, 本文提出了一种将瞬时功率和功率谱熵等特征以及小波变换相结合的心律失常诊断方法, 并在 SVM 与 Bi-LSTM 模型下进行测试。结果表明该方法能够保证在良好的训练性能下, 取得一个较好的识别结果。通过使用 MIT-BIH 心律失常 ECG 数据库进行验证, 该方法在 SVM 中的准确率为 98.33%, 在 Bi-LSTM 中的准确率为 99.37%, 识别速度均在毫秒级, 证明其拥有良好的效

率和识别性能。

2. 数据与方法

2.1. 数据集构成

本文使用了 MIT-BIH 心律失常数据库以构成数据集, 该数据库一共包含 48 个记录, 每个记录包含两个导联的数据, 每个导联时长约为 30 分钟, 采样率为 360 Hz, 对应 650,000 个采样点。其中 23 个记录(100 系列)是从 4000 多份动态心电图带随机选出, 剩下的 25 个记录(200 系列)是挑选出不常见但在临床上重要的心律失常数据, 每个记录都人为标注了各个心拍对应疾病的类型[11]。为定位心拍, 本文使用了经典的 Pan-Tompkins 算法, 然后对定位好的心拍分别向前取 100 个采样点, 向后取 150 个采样点, 组合成 250 个采样点的数据段[12], 从而实现 ECG 信号中 QRS 波群位置的确定, 图 1 所示即为 Pan-Tompkins 心拍定位法结果示意图。




Figure 1. Schematic diagram of Pan-Tompkins cardiopap positioning method

图 1. Pan-Tompkins 心拍定位法示意图

在定位心拍后, 依据标注好的标签, 本文将数据分为四类, 分别为正常心搏(Normal beat)、左束支传导阻滞心搏(LBBB, Left Bundle Branch Block Beat)、右束支传导阻滞心搏(RBBB, Right Bundle Branch Block Beat)、室性早搏(PVC, Premature Ventricular Contraction), 四类数据的波形特点如图 2 所示。本文将两个导联的数据合并, 每类随机选取了 1200 段长度为 2500 个采样点(约为 7 秒)的数据, 构成数据集以用于之后的研究。

2.2. 降噪处理

在实际采集心电的过程中, 信号常常会受到很多干扰, 比如基线漂移、工频干扰、肌电干扰等。为了更好的去除干扰, 并尽可能地保留更多的信息, 本文选择使用小波分解进行降噪, 且由于 symN 小波基所对应的尺度函数和心电信号的波段更为相似[13], 因此选取了 sym8 小波作为基函数。由于基线漂移

频率基本在 0.1 Hz 附近，故要完全去除基线漂移应分解 10 层原信号，将包含高频噪声的 D1 和 D2 层，以及低频干扰的 A10 层去除。处理前后的心电信号对比如图 3 所示，可以看出，经过预处理的信号 R 波更加明显，信号更加平滑。

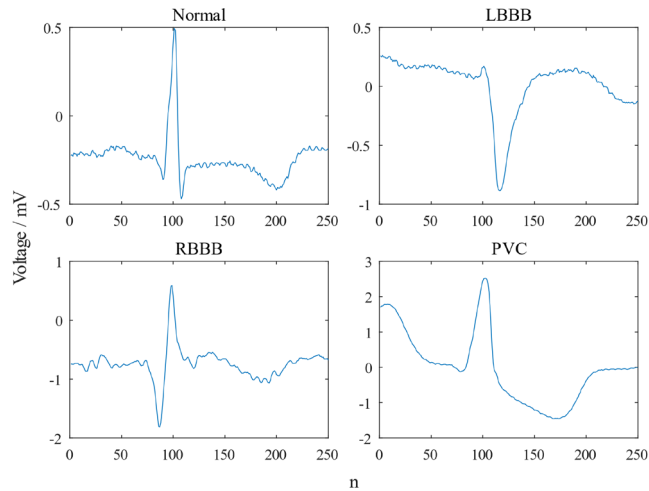


Figure 2. Four types of ECG signal
图 2. 四种类型心电信号




Figure 3. ECG signal de-noising
图 3. 心电信号降噪处理

2.3. 特征选取

心电信号包含许多冗余信息，不利于机器学习的进行，因此本文需要进行恰当的特征选取。常见的特征选择包括计算信号频谱图用作特征来输入二维卷积神经网络[14]，但本次研究特征均为一维变量，因此本文提出在频谱图中提取瞬时频率和功率谱熵，并进行组合，以作为特征。瞬时频率可以评价四类心电信号时变频率变化的特点，其将短时傅里叶变换计算出的频谱图时间窗的中心数据作为输出，即每秒对应一个瞬时频率值，如图 4 所示。而功率谱熵可以测量信号的频谱的稳定性，若信号具有尖峰频谱(如正弦波之和)则拥有低谱熵，若信号具有平坦频谱(如白噪声)则拥有高谱熵，如图 5 所示。




Figure 4. Comparison of instantaneous frequency of four types of ECG signal
图 4. 四种心电信号瞬时频率对比




Figure 5. Comparison of spectral entropy of four types of ECG signal
图 5. 四种心电信号功率谱熵对比

同时，本文依据 SVM 和 Bi-LSTM 网络的特点为其选择了不同的特征组合。由于瞬时频率和功率谱熵的输出值较多，为减少 SVM 的特征维数，本文选择以二者的平均值作为输入，如表 1 所示。

Table 1. Features combination of SVM and Bi-LSTM

表 1. SVM 和 Bi-LSTM 特征组合

SVM 特征	数学意义	Bi-LSTM 特征
瞬时频率平均值	描述信号时变频率	瞬时频率
功率谱熵平均值	反应信号频谱特点	谱熵
模值	反应信号幅值大小	
分形参数[15]	描述信号波形变化	
标准差	反应信号离散程度	
小波能量	分频段描述信号能量分布	
近似熵[16]	反应非线性信号正则性变化	

3. 性能测试

3.1. SVM 模型构建

支持向量机(SVM)是从广义肖像算法发展而来的一种二分类算法,其根据监督学习方式对数据进行二分类。其基于统计理论,以最优分类超平面作为决策边界,在模式识别、数据分类等问题中被广泛使用。在 SVM 算法中,通过核函数来把非线性可分问题从原始特征空间映射至高维空间中,以区分正类和负类,从而增强其可分性。一般采用的核函数包括:拉普拉斯核函数、高斯核函数、多项式核函数和 SIGMOID 核函数[17]。

在本研究中,使用的 SVM 模型是由 MATLAB 中的 Classification Learner 实现。在所有模型中,二次 SVM 表现最为优异,核函数为二次,且对数据进行了标准化。本文使用的验证方法为留出验证法,训练集与测试集之比为 9:1。

3.2. Bi-LSTM 模型构建

传统的机器学习算法较易受限于特征值,泛化能力较弱,而深度学习具有从数据中自我学习有用特征的能力[18],因此,本文在 SVM 的基础上,利用双向长短期记忆网络(Bi-LSTM)进行测试。得益于深度学习具有较大的数据包容性,本文将训练集数据使用 sym8 小波分解重构出 5 个频段的信号,并计算了每个频段的瞬时频率和功率谱熵,以作为 Bi-LSTM 网络的输入。为了加快学习和收敛的速度,本文也对输入数据进行了标准化处理。

长短期记忆网络(LSTM)是对循环神经网络(RNN)的改进,具有 RNN 的记忆性优点,其通过用存储单元和门机制代替隐藏层更新,解决了常规 RNN 梯度消失的局限性。LSTM 单元内有三个门,分别为输入门、遗忘门和输出门,其中,输入门决定是否用输入序列更新 LSTM 单元的状态,遗忘门可以选择性的遗忘或保留 LSTM 单元的当前状态,而输出门负责信息输出,并确定当前的隐藏状态是否传递给下一个迭代[19]。详细的 LSTM 单元结构如图 6 所示。

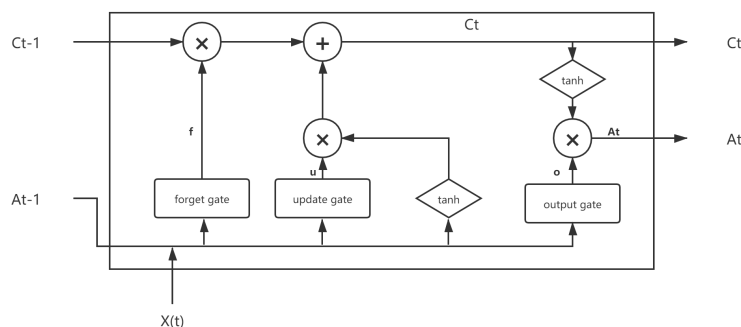


Figure 6. LSTM unit
图 6. LSTM 单元

而 Bi-LSTM 是 LSTM 的改进,是由两个 LSTM 反向组成的,使其神经网络能够双向传输[20]。当向输入层输入一个向量时,双向 LSTM 模型会分别从前后两个方向进行运算。传入隐藏层的值由两个 LSTM 计算出的值共同决定[21]。

本次研究使用的 Bi-LSTM 结构如图 7 所示。为提高学习深度,本文使用了 2 层 bilstm1ayer。为防止过拟合,本文在第 1 层后增加 1 层 dropout,最后输入到 4 层全连接网络中,通过 softmax 激活函数实现信号的分类。此外,由于内存需求小,计算性能更好[22],本文选择使用 Adam 求解器。该 Bi-LSTM 模型的其余参数如表 2 所示。




Figure 7. The net structure of Bi-LSTM
图 7. Bi-LSTM 网络结构

Table 2. Parameter settings
表 2. 参数设置

参数	数量	释义
Num_Hidden	200	每层隐藏单元数
Batch_Size	100	每次输入样本量
Learning_Rate	0.001	学习率
Epochs	100	迭代次数
Gradient_Threshold	1	梯度阈值

该 Bi-LSTM 验证方法与前文介绍的 SVM 验证方法相同，二者的测试平台均为 MATLAB R2020b。

4. 实验结果与分析

在模型测试中，本文分别对有标签的 ECG 样本特征进行四分类训练，其中训练集与测试集共包含 480 个采样数据，该四分类将心电数据划分为正常心搏(Normal)、左束支传导阻滞心搏(LBBB)、右束支传导阻滞心搏(RBBB)与室性早搏(PVC)。最终，本文得到了 SVM 与 Bi-LSTM 两种模型下分类结果的混淆矩阵，如图 8 所示。

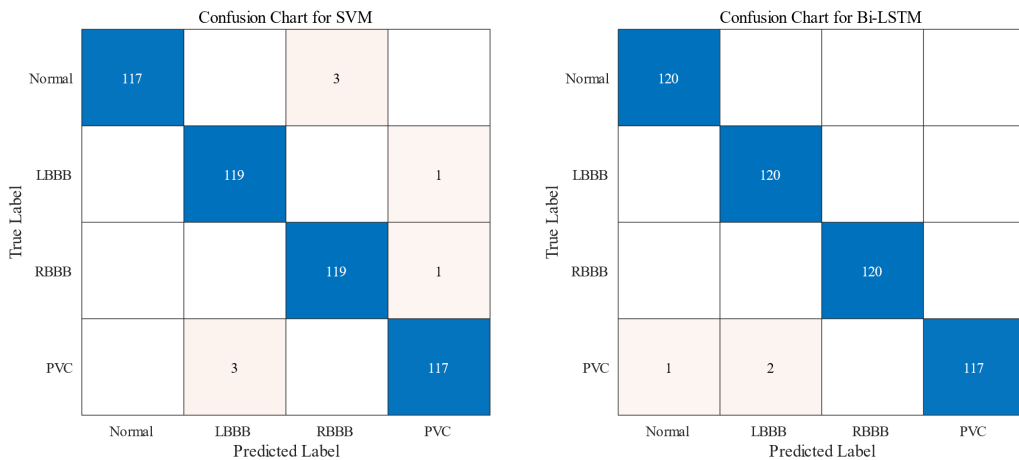


Figure 8. Confusion matrix of classification results of SVM (left) and Bi-LSTM (right) algorithms
图 8. SVM (图左)与 Bi-LSTM (图右)算法所得分类结果的混淆矩阵

在该混淆矩阵中，实际标签(True Label)与预测标签(Predicted Label)分别代表实际数据与算法预测数据分布。根据混淆矩阵数据，本文计算了两种分类算法的准确率(Accuracy)、灵敏度(Sensitivity)、召回率(Recall)与 F₁-score，具体数值如表 3 所示。

Table 3. Algorithm evaluation index

表 3. 算法评价指标

分类类别	Accuracy		Precision		Recall		F ₁ -score	
	SVM	Bi-LSTM	SVM	Bi-LSTM	SVM	Bi-LSTM	SVM	Bi-LSTM
Normal	99.38%	99.79%	100.00%	99.17%	97.50%	100.00%	98.73%	99.59%
LBBB	99.17%	99.58%	97.54%	98.36%	99.17%	100.00%	98.35%	99.17%
RBBB	99.17%	100.00%	97.54%	100.00%	99.17%	100.00%	98.35%	100.00%
PVC	99.38%	99.38%	100.00%	100.00%	97.50%	97.50%	98.73%	98.73%

在混淆矩阵之外，本文也对两种模型的受试者工作特征曲线(ROC curve)进行了计算，其结果如图 9 与图 10 所示。ROC 曲线可反映模型的区分能力，X 轴方向表示假阳性率(False Positive Rate)，Y 轴方向表示真阳性率(True Positive Rate)。ROC 曲线下方包络面积大小为 AUC (Area Under Curve)，AUC 面积在 0.9 以上则表示模型性能优异。由此 ROC 曲线可知，本方法在 SVM 与 Bi-LSTM 模型下都具备对于心律失常 ECG 信号的高准确度分类能力，而 Bi-LSTM 模型相较于 SVM 模型具有更好的时域结构特点，也具有更好的分类性能，可有效区分出正常心搏、左束支传导阻滞心搏、右束支传导阻滞心搏与室性早搏四种心律信号。

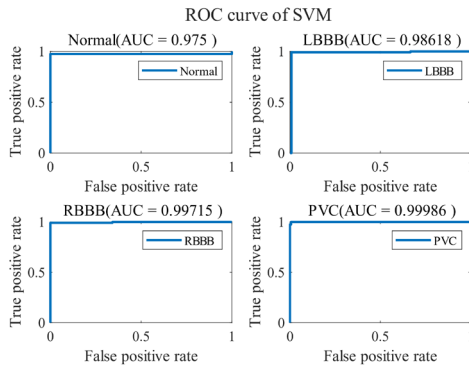


Figure 9. ROC curves of SVM
图 9. SVM 模型的 ROC 曲线

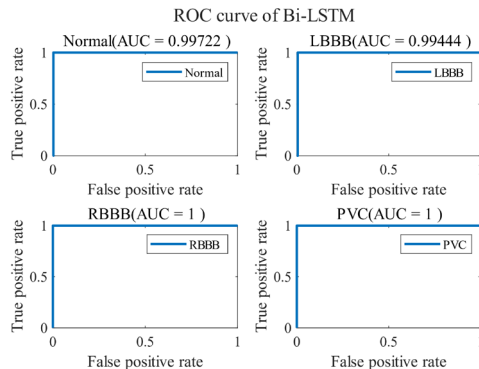


Figure 10. ROC curves of Bi-LSTM
图 10. Bi-LSTM 模型的 ROC 曲线

此外, 本文也对该方法的时间损耗进行测试, 并与传统的非线性动力学特征进行比较。本文计算并统计了 SVM 和 Bi-LSTM 方法下计算特征并完成识别的时间, 与传统的非线性特征(包括排列熵、Lyaouniv 指数等)消耗的时间进行对比, 其结果如图 11 所示。由此可知, 在使用本文所提出的瞬时频率与功率谱熵融合特征的情况下, SVM 模型与 Bi-LSTM 模型的时间损耗缩短至 6.92%左右, 识别速率达到毫秒级, 因此本文所提出的方法具有更好的时间性能。

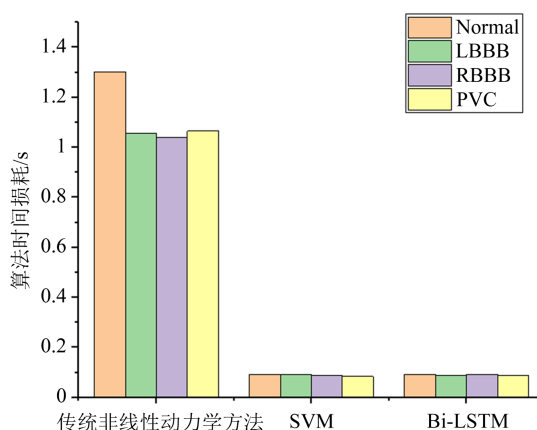


Figure 11. Comparison of four classifications task time loss of the proposed method and traditional nonlinear dynamics methods

图 11. 本文提出方法与传统非线性动力学方法的四分类任务时间损耗对比

5. 结束语

本文针对心律异常信号的特点, 通过应用瞬时频率和功率谱熵融合特征以及 Pan-Tompkins 算法, 对基于机器学习的心律失常诊断方法进行改进。在使用 MIT-BIH 数据库构建的数据集的测试中, 该方法在 SVM 和 Bi-LSTM 下的准确率分别为 98.3%和 99%, 相对于使用传统的非线性动力学特征, 二者的都得到了更高的分类精准水平与更快的时间响应性能。该方法弥补了当前心律失常诊断方法的不足, 为高效率、高准度的心律失常诊断提供了一种可能。

致 谢

感谢东北大学医学与生物信息工程学院石晶晶副教授、刘海莲同学、张嘉玉同学, 以及人体通信实验室其他成员的指导与帮助。

基金项目

本项目得到了东北大学医学与生物信息工程学院 SIVI 计划的资助, 项目编号为 191186。

参考文献

- [1] Roth, G.A., Mensah, G.A., Johnson, C., Addolorato, G., Ammirati, E., Baddour, L.M., *et al.* (2020) Global Burden of Cardiovascular Diseases and Risk Factors, 1990-2019: Update from the GBD 2019 Study. *Journal of the American College of Cardiology*, **76**, 2982-3021. <https://doi.org/10.1016/j.jacc.2020.11.010>
- [2] 马丽媛, 吴亚哲, 陈伟伟. 《中国心血管病报告 2018》要点介绍[J]. 中华高血压杂志, 2019, 27(8): 712-716.
- [3] 杨宝峰, 蔡本志. 心律失常发病机制研究进展[J]. 国际药学研究杂志, 2010, 37(2): 81-88.
- [4] 任良英. 心律失常诊断中应用动态心电图的价值分析[J]. 中西医结合心血管病电子杂志, 2020, 8(13): 92.
- [5] 袁佳栋, 王群山. 人工智能在心律失常诊断中的前景与挑战[J]. 心血管病学进展, 2020, 41(10): 999-1001, 1006.

- [6] 宋绮蕊, 蔡军. 人工智能及机器学习在心血管疾病中的应用[J]. 基础医学与临床, 2020, 40(5): 707-710.
- [7] Mohri, M., Rostamizadeh, A. and Talwalkar, A. (2018) Foundations of Machine Learning. 2nd Edition, The MIT Press, Cambridge, 1.
- [8] 王金海, 史梦颖, 张兴华. 基于 EMD 和 ApEn 特征提取的心律失常分类研究[J]. 仪器仪表学报, 2016, 37(S1): 168-173.
- [9] Pecchia, L., Melillo, P., Sansone, M. and Bracale, M. (2011) Discrimination Power of Short-Term Heart Rate Variability Measures for CHF Assessment. *IEEE Transactions on Information Technology in Biomedicine*, **15**, 40-46. <https://doi.org/10.1109/TITB.2010.2091647>
- [10] Acharya, U.P., Oh, S.L., Hagiwara, Y., Tan, J.H., Adam, M., Gertych, A., et al. (2017) A Deep Convolutional Neural Network Model to Classify Heartbeats. *Computers in Biology and Medicine*, **89**, 389-396. <https://doi.org/10.1016/j.compbiomed.2017.08.022>
- [11] Moody, G.B. and Mark, R.G. (2001) The Impact of the MIT-BIH Arrhythmia Database. *IEEE Engineering in Medicine and Biology Magazine*, **20**, 45-50. <https://doi.org/10.1109/51.932724>
- [12] 张俊飞, 毕志升, 王静, 吴小玲. 基于深度学习的 ECG 心拍数据分类设计[J]. 自动化与仪器仪表, 2019(12): 71-75.
- [13] 陈义. 心电信号的异常心律分类算法研究[D]: [硕士学位论文]. 重庆: 重庆大学, 2016.
- [14] Wang, D. (2017) Deep Learning Reinvents the Hearing Aid. *IEEE Spectrum*, **54**, 32-37. <https://doi.org/10.1109/MSPEC.2017.7864754>
- [15] Yang, H., Yuan, Y., Wang, X. and Li, X. (2020) Closed-Loop Transcranial Ultrasound Stimulation for Real-Time Non-Invasive Neuromodulation in Vivo. *Frontiers in Neuroscience*, **14**, 445. <https://doi.org/10.3389/fnins.2020.00445>
- [16] Rizwan, M., Whitaker, B.M. and Anderson D.V. (2018) AF Detection from ECG Recordings Using Feature Selection, Sparse Coding, and Ensemble Learning. *Physiological Measurement*, **39**, Article ID: 124007. <https://doi.org/10.1088/1361-6579/aaf35b>
- [17] 龙亦凡, 乔雯钰, 孙静. 基于 SVM 的大屯矿区遥感影像变化检测[J]. 测绘与空间地理信息, 2020, 43(12): 107-110+115.
- [18] 张异凡, 黄亦翔, 汪开正, 刘成良. 用于心律失常识别的 LSTM 和 CNN 并行组合模型[J]. 哈尔滨工业大学学报, 2019, 51(10): 76-82.
- [19] Elsheikh, A., Yacout, S. and Ouali, M. (2019) Bidirectional Handshaking LSTM for Remaining Useful Life Prediction. *Neurocomputing*, **323**, 148-156. <https://doi.org/10.1016/j.neucom.2018.09.076>
- [20] 赵志宏, 赵敬娇, 魏子洋. 基于 BiLSTM 的滚动轴承故障诊断研究[J]. 振动与冲击, 2021, 40(1): 95-101.
- [21] 谢思雅, 施一萍, 胡佳玲, 陈藩, 刘瑾. 基于 BiLSTM-ATT 的微博用户情感分类研究[J]. 传感器与微系统, 2021, 40(2): 26-29.
- [22] 龚安, 张敏. BP 网络自适应学习率研究[J]. 科学技术与工程, 2006, 6(1): 64-66.