

DOI:10.11918/j.issn.0367-6234.201810178

用于心律失常识别的 LSTM 和 CNN 并行组合模型

张异凡,黄亦翔,汪开正,刘成良

(上海交通大学 机械科学与动力工程学院,上海 200240)

摘 要: 心脏病是导致人类死亡的首要原因,而大部分心血管疾病往往伴随着心律失常出现.为实现对不同类型心电图信号的自动分析、识别异常心律,研究并提出了一种基于深度学习的心拍分类算法.考虑到心电图自身的特性,使用长短时记忆网络来捕捉心电序列数据的前后依赖关系,结合卷积神经网络提取局部相关特征,自动识别 5 种不同类型的心拍.基于 LSTM 和 CNN 的深度学习方法将经过预处理的心电信号后直接作为网络的输入,将心电分类的特征提取、分类两个步骤融合为单个学习器.针对类别数据不平衡问题,通过对少数类样本滑窗采样获得更多训练数据.使用 MIT-BIH 数据集验证模型的有效性,最终在测试集 2 万多个心拍记录中分类结果准确率达到 99.11%,特异性为 99.44%,灵敏度为 97.27%,此外滑窗采样操作对少数类样本的灵敏度有明显改善.实验结果表明,相比传统的 SVM 和随机森林等方法,基于 LSTM 和 CNN 的并行组合模型不需要人工提取复杂特征,且达到了更好的分类性能,适用于可穿戴式心电设备和远程监护领域.

关键词: 心拍分类;长短时记忆网络;卷积神经网络;滑窗采样;特征提取

中图分类号: TP183 **文献标志码:** A **文章编号:** 0367-6234(2019)10-0076-07

Arrhythmia classification using parallel combination of LSTM and CNN

ZHANG Yifan, HUANG Yixiang, WANG Kaizheng, LIU Chengliang

(School of Mechanical Engineering, Shanghai Jiao Tong University, Shanghai 200240, China)

Abstract: Heart disease is the leading cause of death in humans, and most cardiovascular diseases are accompanied by arrhythmias. In order to realize the automatic analysis of different types of electrocardiogram (ECG) signals and recognize abnormal heart rhythm, a new classification algorithm based on deep learning was studied and proposed. Considering the characteristics of the ECG, the convolutional neural network (CNN) was used to extract the local correlation features, and the long-short term memory (LSTM) network was used to capture the long-term dependence of ECG sequence data to identify five different types of heart beats automatically. The deep learning method based on LSTM and CNN directly took the preprocessed ECG signals as the input of the network, and integrated the feature extraction and ECG classification into a single learner. In terms of the problem of imbalance, sampling by sliding window was performed on minority class data to get more training data. The effectiveness of the algorithm was evaluated with the MIT-BIH arrhythmia dataset, and the accuracy, specificity, and sensitivity of the classification results in more than 20 000 cardiac beats recorded in the test set reached 99.11%, 99.44%, and 97.27%, respectively. In addition, the operation of sliding window sampling significantly improved the sensitivity of minority class. The experimental results show that compared with the traditional methods, the parallel combination model based on LSTM and CNN did not require separate feature extraction steps and achieved better classification performance, which is suitable for wearable ECG devices and remote monitoring field.

Keywords: heart beats classification; long-short term memory; convolutional neural network; moving window; feature extraction

心电信号记录了心脏每一心动周期所产生的电位变化,是重要的生命特征和评价心脏健康状况的重要依据.心脏病是导致人类死亡的首要原因,根据世界卫生组织(WTO)统计数据显示,2015年约有

1 770万人死于心血管疾病,且心脏病有低龄化的趋势^[1].心律失常是心血管疾病中最为常见的病症之一,长期心律失常不仅会导致严重的心脏病,由于人们对自身健康的重视和医疗资源的不平衡,基于心律失常分类算法的计算机辅助医疗手段应时而生^[2].根据美国医疗仪器促进协会(AAMI)制定的标准,心拍可以被分为5大类:非异位(N)、室上性异位(S)、室性异位(V)、融合心跳(F)和未知心跳(Q)^[3].能够准确、快速地识别出异常心律,对人们

收稿日期: 2018-10-28
基金项目: 国家重点研发计划(2017YFB1302004)
作者简介: 张异凡(1995—),男,硕士研究生;
刘成良(1964—),男,博士生导师,长江学者特聘教授
通信作者: 刘成良,blazefloyd@hotmail.com

了解自身心脏的健康状况、挽救病人生命具有重要意义。

随着信息技术和人工智能技术的发展,心电自动分类方法已经得到了长足的发展,目前对于心电图的分类识别主要包含两类:基于波形形态的分类方法和基于波形特征的分类方法。基于波形形态的方法,根据提取的特征波形计算每个波段之间的间期,每个波的幅值、波宽、斜率等特征,结合医学上的诊断规则判断。

而基于波形特征的分类算法,主要包含信号预处理、特征提取和分类识别 3 个部分。心电图一般含有多个心拍,一个心拍由 P 波、QRS 波群、T 波等构成。提取基于波形特征的心电信息特征需要对这些波形进行准确检测,常见的波形检测算法有小波变换^[4]、模板匹配法^[5]、图形识别法^[6]、能量阈值法^[7]等。目前基于 R 波的检测方法准确率比较高,而 P 波、T 波幅值低,特征提取算法仍然不够成熟。心电图特征提取方法还包括小波变换法^[8]、功率谱特征^[9]、高阶统计量法^[10]、主成分分析^[11]等。李坤阳等^[12]结合小波变换和形态学检测出 QRS 波群的特征点,由 QRS 波宽和 RR 间期等参数,结合医疗知识对心拍进行 4 分类,准确率达到 94.2%。2016 年 Li 等^[13]利用小波包分解、小波包信息熵和 RR 间期,由随机森林算法对心电信号进行五分类,最终到达了 94.61% 的准确率。Khazaee 等^[14]首先计算心电信号的功率谱并用于心电分类。Elhaj 等^[15]将高阶统计量等非线性特征与独立成分分析得到的非线性特征与对离散小波变换系数进行主成分分析得到的线性特征相结合。传统的心电图分类算法的缺陷在于需要设计特征提取方法提取有用信息,从而结合机器学习算法进行分类,在这一过程中使用 PCA、小波变换等方法的非线性拟合能力有限,而且必然伴随着部分信息的丢失,当提取的特征不能反应数据中的内在属性,分类算法的效果表现将会很差。Kiranyaz 等^[16]提出将一维卷积神经网络用于心电信号分类。

与传统方法不同,基于深度学习的方法具有从 ECG 信号中自我学习有用特征的能力,从而从数据中挖掘复杂的关联模式和丰富的信息。如果使用深度神经网络(DNN),其假设神经元的输入的数据是相互独立的,尽管可以通过增加纵向隐层神经元和横向增加层来提高非线性拟合能力,但是随着网络结构的加深,将会导致过拟合和梯度消失问题。同时 ECG 信号作为一个时间序列,对心拍分类时常常考虑到波形特征以及各个波形的联系,因此针对 ECG 信号的前后信息依赖关系和局部相关性,本文提出

了结合 LSTM 和 CNN 的心电图分类模型。

1 方 法

1.1 数据预处理

在心电信号采集过程中常会夹杂着各种噪声,比如基线漂移、工频干扰、肌电扰动,噪声的存在会在一定程度上影响心电分类的准确率,为了抑制噪声,提高 ECG 信号的信噪比,需要在将数据传入神经网络之前进行滤波处理。本文采取小波方法降噪,具体对小波系数分析,将绝对值较小的系数置 0,保留或收缩绝对值较大的系数,之后对处理后的小波系数进行重构得到消噪信号。由图 1 可知,小波变换法比较好地消除了噪声,同时保留了有用信号。




图 1 小波方法降噪前、后 ECG 信号对比
Fig. 1 ECG signal comparison before and after noise reduction using wavelet method

1.2 长短时记忆网络

长短时记忆网络(LSTM)是一种特殊的循环神经网络。LSTM 与标准 RNN(循环神经网络)的区别在于它通过引入门机制(gated mechanism)和记忆单元(memory cell),克服了传统 RNN 存在梯度消失和梯度爆炸的缺陷,在提取序列数据的长期依赖关系方面也表现更好,因此 LSTM 适合应用于具有时序特性的心电信号。

如图 2 所示,LSTM 的隐藏层由输入门(input gate)、输出门(output gate)、遗忘门(forget gate)组成。这 3 个控制门可以使 LSTM 神经元完成读、写、重置和更新长距离历史信息的操作。LSTM 隐藏层的输入包括当前序列的输入 x_t ,上一时刻隐藏层的状态 c_{t-1} ,以及输出向量 h_{t-1} ,经过计算得到当前状态输出 h_t 并更新状态得到 c_t 。LSTM 的结构中遗忘门决定上一时刻细胞状态 c_{t-1} 中的多少信息可以传递到当前时刻 c_t 中。在输入门中 tanh 函数用来产生当前时刻信息的信息,sigmoid 函数用来控制有多少新信息可以传递给细胞状态。输出门基于新的细胞

状态 c_t 得到当前状态对应的输出 h_t .




图 2 LSTM 网络单元结构图

Fig. 2 Hidden layer of LSTM

LSTM 具体的更新方式如下^[17]：

$$i_t = \sigma(W_{xi}x_t + W_{hi}h_{t-1} + b_i), \quad (1)$$

$$f_t = \sigma(W_{xf}x_t + W_{hf}h_{t-1} + b_f), \quad (2)$$

$$o_t = \sigma(W_{xo}x_t + W_{ho}h_{t-1} + b_o), \quad (3)$$

$$\tilde{c}_t = \tanh(W_{xc}x_t + W_{hc}h_{t-1} + b_c), \quad (4)$$

$$c_t = f_t \cdot c_{t-1} + i_t \cdot \tilde{c}_t, \quad (5)$$

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

式中： c_t 为记忆单元的状态信息； $\tilde{c}_t$ 为当前时刻的积累的信息； W 为不同门的权重系数矩阵； b 为对应的偏置项； σ 、 $\tanh$ 分别为 sigmoid 激活函数和双曲正切激活函数。

根据式(5)可以知道，在 LSTM 中当前时刻的状态信息 c_t 与此前的状态信息 c_{t-1} 是线性关系。当遗忘门是打开的，即 sigmoid 单元输出接近为 1 的时候，不会出现梯度消失，新的状态信息是之前状态信息和当前时刻累计信息的加权平均，所以无论序列的长度如何，只要遗忘门是打开的，网络就能记住过去的状态信息，即 LSTM 能够捕捉长期依赖关系。

1.3 卷积神经网络

卷积神经网络是一种前馈型神经网络，除输入层、输出层之外主要包含卷积层和池化层，其特殊的网络结构可以有效地降低神经网络的复杂性，在很多领域尤其是图像识别方面取得了巨大的成功^[18]。

其中卷积层输出通过卷积核与上一级输入层局部连接，根据步长逐步滑动窗口获得。对应的局部特征与卷积核的各个参数相乘，在滑动过程中卷积核的权值保持不变，即权值共享。通常每个卷积层有多个卷积核，可以提取到不同的特征。通过卷积获得了图像的特征之后可以直接根据这些特征训练分类器，但是这样计算量很大而且容易产生过拟合，因此在卷积层后面加入池化层来缩小特征图谱矩阵，减少计算量，同时增强了对特征识别的抗干扰能力，比如图片的变形和扭曲。CNN 通过局部连接、权值共享和池化很大程度上降低了网络的复杂度。




图 3 卷积神经网络结构

Fig. 3 Structure of CNN

对于多导联心电图，视为多通道的一维数据，因此本文利用一维卷积作为卷积层来提取心电信号特征，一维卷积神经网络结构如图 4 所示。




图 4 一维卷积神经网络结构

Fig. 4 One-dimensional CNN

在卷积层中神经元与输入层的一个局部窗口相连，一维卷积实际提取的是时间轴上的短期特征，能比较好的反映时间序列的局部相关特征。一维卷积层的第 i 个神经元的输出为

$$y_i = f\left(\sum_{j=1}^m w_j \cdot x_{i-j+m} + b\right).$$

式中： $x_i (i=1, 2, \dots, n)$ 为输入的序列； w_j 为卷积核的权重系数矩阵； b 为偏置系数； m 为卷积核的个数； f 为卷积层的激活函数。

1.4 结合 LSTM 和 CNN 的神经网络模型

每种不同的深度学习方法都有独特的方式来提取特征，CNN 模型通过卷积核来捕捉输入中的局部相关特征，但是滤波器尺寸的限制使得 CNN 难以学习到序列数据中的前后依赖关系，而 LSTM 通过引入记忆单元和门机制能够弥补这一缺陷。因此本文提出 LSTM 和 CNN 并行组合的深度学习方法来完成心电图的自动分类^[19]。

本文设计的 LSTM-CNN 模型如图 5 所示，输入层的维度是 300×2 （见 MIT-BIH 数据库），由通过 LSTM 层提取时序特征，以及经过并行的卷积网络结构捕捉丰富的局部关联信息，将卷积特征和 LSTM 提取的时序特征融合到全连接层，最后由 Softmax 层输出多分类结果。

1.5 数据增强

深度学习模型因为其结构特点具有很强的表达解释能力，但是当数据量较小的时候比较容易发生过拟合，在本文中心电图分类是一个不平衡问题，S、V、F、Q 类的数量明显小于 N 类，因此增加样本数量

有利于提高模型的泛化能力. 在图像分类任务中, 常采取镜像、旋转、尺度变换、裁剪、噪声扰动等方法扩充数据. 考虑到心电数据的周期性, 本文通过滑窗的方式来获取更多训练数据, 即对于一个心搏可以通过移动窗口起始点位置获得包含完整心拍的多个训练样本. 具体对训练集少数类样本进行滑窗取样处理, 使 5 类 ECG 记录的数量接近一致.

表 1 结合 CNN 和 LSTM 的模型结构参数

Tab. 1 Network structure parameters of LSTM-CNN model

编号	层类型	输出维度	核大小	步长
1	Input layer	300×2	-	-
2	1 st LSTM layer	300×64	-	-
3	2 nd LSTM layer	64	-	-
4	1 st Convolution layer	296×64	5	1
5	1 st Pooling layer	98×64	3	3
6	2 nd Convolution layer	94×32	5	1
7	2 nd Pooling layer	31×32	3	3
8	Flatten	992	-	-
9	Concatenate	1 056	-	-
10	1 st Full-connected layer	64	-	-
11	2 nd Full-connected layer	32	-	-
12	Softmax	5	-	-




图 5 LSTM 与 CNN 并行结合的神经网络模型结构

Fig. 5 Structure of neural network model using parallel combination of LSTM and CNN

2 实验与结果分析

2.1 MIT-BIH 数据库

为了验证和比较模型的分类效果, 本文采用 MIT-BIH 数据库来验证模型效果. MITDB 心律失常子数据库包含了 48 条 ECG 记录, 每条记录长 30 min 左右, 采样频率为 360 Hz^[20]. 每条 ECG 记录由两个导联组成, 考虑到每条记录的导联并不相同, 为了保持数据分布的一致, 本文仅利用包括 II 导联和 V1 导联的 40 条记录. 为了和已发表的文献对比, 根据 R 峰的位置对 ECG 信号进行分割, 取 R 点前 100 个采样点和后 199 个点, 包括 R 波在内的共 300 个采样点作为一个训练样本, 最终从 40 条记录中提取共 94 131 个样本, 将 23 533 个样本作为测试集, 其余样本作为训练集. 将心拍按 AAMI 标准划分为 5 类, 5 种类型的心拍的数量见表 2.

表 2 5 种类型的心拍数量

Tab. 2 Data distributions of five types of heart beats

心拍类型	数量
N	79 607
S	2 702
V	7 135
F	793
Q	3 894
总计	94 131

2.2 实验平台及评价指标

实验平台硬件配置为 Intel i7-6700 CPU, 显卡为 GTX1060, 内存是 32 G, 操作系统为 Ubuntu 16. 04 系统, 模型基于 Python 语言和 Tensorflow 框架实现.

在心跳分类的相关研究中, 通常以准确性、特异性和敏感性为指标来评价模型的性能. 混淆矩阵表示模型的分类结果的详细信息, 在多分类问题中混淆矩阵的每一行代表真实类别, 每一列代表预测类别. 对于 K 类的多分类问题, 混淆矩阵是一个 K 维的矩阵.

Pred

1

⋮

i

⋮

K

$$1 \begin{bmatrix} n_{11}^T & \cdots & n_{1i}^F & \cdots & n_{1K}^F \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ i \begin{bmatrix} n_{i1}^F & \cdots & n_{ii}^T & \cdots & n_{iK}^F \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ K \begin{bmatrix} n_{K1}^F & \cdots & n_{Ki}^F & \cdots & n_{KK}^T \end{bmatrix} \end{bmatrix} \begin{bmatrix} C_1 \\ \vdots \\ C_i \\ \vdots \\ C_K \end{bmatrix}$$

Label

P_1

⋮

P_i

⋮

P_K

式中: n_{ij}^F 为类别为 i 的样本的数量被归类为类 j 的数

量, n_{ii}^T 为类别为 i 的样本的被正确分类的数量. P_i 为所有样本被分类为 i 的数量, C_i 为类别为 i 的样本数量. 对于类别 i , 特异性、灵敏度和准确率的计算方式如下:

$$\text{Spe} = \frac{\sum_{m \neq i} \sum_{l \neq i} n_{ml}}{\sum_{m=1}^K \sum_{l=1}^K n_{ml} - P_i},$$
$$\text{Sen} = \frac{n_{ii}^T}{C_i},$$
$$\text{Acc} = \frac{n_{ii}^T + \sum_{m \neq i} \sum_{l \neq i} n_{ml}}{\sum_{m=1}^K \sum_{l=1}^K n_{ml}}.$$

式中: 准确率 (Acc) 为被正确分类的心拍所占的比例; 特异性 (Spe) 为所有负例中被正确分类的比例, 衡量了模型对负例的识别能力; 灵敏度 (Sen) 为所有正例中被正确分类的比例, 衡量了模型对正例样本的识别能力.

2.3 结果与分析

表 3 的混淆矩阵表示 LSTM 和 CNN 并行组合模型的心电图分类结果. 值得注意的是, 由于不同类别样本的数量不平衡, 模型对 N, V, Q 类都有比较好的识别能力, 但是对 S, F 类的识别能力较差. N 类的特异性较低, 表示模型倾向于将非 N 类心拍分类为 N 类, 即正常心拍, 这在心脏病诊断中是危险的.

表 3 心率分类的实验结果

Tab. 3 Experimental results of heart beats classification

类别	预测					Acc/%	Spe/%	Sen/%
	N	S	V	F	Q			
N	19 858	18	30	4	2	99.07	95.42	99.73
S	97	539	7	0	0	99.47	99.91	83.83
V	32	3	1 746	12	0	99.57	99.76	97.38
F	33	0	13	158	0	99.74	99.93	77.45
Q	4	0	3	0	974	99.97	99.99	99.29

表 5 本文分类效果与其他方法对比

Tab. 5 Comparison of classification performance by the proposed method and other methods

		%							
文献	方法	Acc	Spe	Sen	N-Sen	S-Sen	V-Sen	F-Sen	Q-Sen
本文	LSTM + CNN	99.11	99.44	97.27	99.44	91.48	98.04	83.49	99.69
文献[21]	CNN	94.03	91.54	96.71	91.54	90.59	94.22	96.06	97.75
文献[13]	WPE + RR + RF	94.61	—	—	94.69	20.00	94.20	50.00	—
文献[22]	RR + WT + LP	86.50	—	—	91.90	81.00	86.60	—	—
文献[23]	DWT + ICA + PCA + RR	93.62	—	—	95.35	28.17	75.27	12.50	—
文献[24]	HOS + PCA + LS - SVM	93.48	99.27	98.31	—	—	—	—	—

正如数据增强中提到的, 本实验对少数类数据进行滑动窗口采样, 以抑制样本不平衡对模型性能的负面影响. 从表 4 可以得知, LSTM 和 CNN 并行组合模型经过类别平衡的数据训练后, S 类和 F 类的灵敏度分别提高了 7.65% 和 6.04%. 通过比较证明了样本平衡策略提高了模型的分类性能.

表 5 总结了已有的心电图分类算法 5 分类的结果, 评价指标 N-Sen, S-Sen, V-Sen, F-Sen, Q-Sen 分别为每一类样本的敏感性. 表中 WPE 为小波熵, RR 为 RR 间期, RF 为随机森林算法, WT 为双尺度小波变换, LP 为线性预测特征, DWT 为离散小波变换, ICA 为独立成分分析, HOS 为高阶统计特征 (higher order statistics), LS-SVM 为最小二乘支持向量机.

表 4 数据增强后心率分类的实验结果

Tab. 4 Experimental results of heart beats classification after data augment

类别	预测					Acc/%	Spe/%	Sen/%
	N	S	V	F	Q			
N	19 835	49	41	16	6	99.11	97.27	99.44
S	58	623	0	0	0	99.52	99.76	91.48
V	23	5	1 703	5	1	99.59	99.72	98.04
F	16	0	19	177	0	99.76	99.91	83.49
Q	1	0	1	1	951	99.96	99.97	99.69

基于各种特征提取方法的传统机器学习方法整体准确率较低, 而且对异常分类的识别能力比较差, 这表明常用的特征提取函数的拟合能力有限, 未能完全捕捉到心电图中的隐藏特征. 通过对比可以得出, 本文通过结合 LSTM 和 CNN 的深度学习模型, 即利用 LSTM 提取心电图的时序特性, 以及利用 CNN 提取局部关联特征的能力, 模型能够自动提取特征并达到更高的准确率.

2.4 讨论

传统心电分类算法由特征提取和分类器两部分组成. 使用 PCA、LDA、ICA 等方法构造特征后送入 SVM 等分类器训练和分类. PCA 采用了 K-L 变换中的协方差变换矩阵, 通过一系列的线性变换之后, 找到一组正交的单位投影轴, 并利用该投影轴重建原样本, ICA 实现了盲源分离, LDA 利用了训练样本的类别标记, 三者都是线性模型, 缺点在于容易造成高阶统计特征的缺失, 使特征描述不充分. 解决办法是引入核函数将样本映射到一个高维空间, 问题在于选择核函数与核函数的参数较为困难. 传统的心电特征提取方法非线性拟合能力有限, 在对信号进行特征描述、剔除冗余噪声时, 也丢失了部分有用信息, 而且相比深度学习方法直接输入原始信号引入了中间误差; 当采用多种特征融合的方式对信号进行描述, 特征选择仍需大量实验验证且分类过程相对复杂.

本文采用的基于 LSTM 和 CNN 并行组合的心电图分类算法的输入是原始信号, 模型本身包含了特征提取部分. 将特征提取和分类过程独立进行的缺点在于当特征提取算法未能有效捕捉心电数据中的关联模式, 分类器的表现较差时, 分类效果的好坏无法自动反馈到特征提取过程. 而本文提出的模型比较好地捕捉了信号的局部相关性和前后依赖关系, 同时基于反向传播算法调整模型参数使得代价函数最小.

3 结 论

1) 本文针对 ECG 分类算法进行了深入的研究, 针对心电图的特性, 提出了结合 LSTM 和 CNN 并行组合的 ECG 自动分类模型, 此方法能够提取出心电图的局部相关特征和长期依赖关系. 相比传统的心电分类算法, LSTM-CNN 模型能够自动提取到心电图的有效特征并准确判断心电图的类别且达到更高的分类性能, 在 MITDB 的 2 万多个样本中测试结果准确率为 99.11%, 特异性为 99.44%, 灵敏度为 97.27%.

2) 本文提出的模型不局限于心拍的类型, 具有推广性和实际价值, 可适用于不同类型的心电疾病诊断. 在未来的工作中, 网络结构及参数的选定、集成学习、从医疗知识方方面构造特征等方面都值得进一步研究, 比如尝试基于 Attention 机制的 LSTM 模型, 提取 RR 间期以及借鉴 Resnet 的残差块结构, 加深网络提高泛化能力.

参考文献

[1] World Health Organization. Cardiovascular diseases (CVDs) [EB/

OL]. [2017-07-05]. <http://www.who.int/mediacentre/factsheets/fs317/en>

- [2] 宋俊雅, 袁永峰, 王宽全. 心室电传导模型的心律失常机制仿真分析[J]. 哈尔滨工业大学学报, 2014, 46(1): 34
SONG Junya, YUAN Yongfeng, WANG Kuanquan. Simulation of arrhythmia mechanism based on ventricular electrical conduction model [J]. Journal of Harbin Institute of Technology, 2014, 46(1): 34
- [3] ANNAM J R, SURAMPUDI B R. AAMI based ECG heart-beat time-series clustering using unsupervised ELM and decision rule [C]// International Conference on Information Technology (ICIT). Bhubaneswar, India; IEEE, 2017. DOI:10.1109/ICIT.2016.039
- [4] STOJANOVIĆ R, KARADAGLI Ć D, MIRKOVIĆ M, et al. A FPGA system for QRS complex detection based on integer wavelet transform[J]. Measurement Science Review, 2011, 11(4): 131. DOI: 10.2478/v10048-011-0024-z
- [5] NAKAI Y, IZUMI S, NAKANO M, et al. Noise tolerant QRS detection using template matching with short-term autocorrelation [C]//Proceedings of the 36th Annual International Conference of the IEEE Engineering in Medicine and Biology Society. Chicago, IL; IEEE, 2014. DOI:10.1109/EMBC.2014.6943522
- [6] CHRISTOV I, GOMEZ-HERRERO G, KRASTEVA V, et al. Comparative study of morphological and time-frequency ECG descriptors for heartbeat classification[J]. Medical Engineering & Physics, 2006, 28(9): 876. DOI:10.1016/j.medengphy.2005.12.010
- [7] CHOUHAN V S, MEHTA S S. Detection of QRS complexes in 12-lead ECG using adaptive quantized threshold [J]. International Journal of Computer Science and Network Security, 2008(1):155
- [8] MINHAS F, ARIF M. Robust electrocardiogram (ECG) beat classification using discrete wavelet transform [J]. Physiological Measurement, 2008, 29(5): 555. DOI: 10.1016/j.vaccine.2009.01.115
- [9] ZHANG Yatao, LIU Chengyu, WEI Shoushui, et al. ECG quality assessment based on a kernel support vector machine and genetic algorithm with a feature matrix[J]. Journal of Zhejiang University Science C: Computer & Electronics, 2014, 15(7): 564. DOI:10.1631/jzus. C1300264
- [10] KUTLU Y, KUNTALP D. Feature extraction for ECG heartbeats using higher order statistics of WPD coefficients [J]. Computer Methods and Programs in Biomedicine, 2012, 105(3): 257. DOI: 10.1016/j.cmpb.2011.10.002
- [11] MARTIS R J, ACHARYA U R, MIN L C. ECG beat classification using PCA, LDA, ICA and discrete wavelet transform [J]. Biomedical Signal Processing and Control, 2013, 8(5): 437. DOI: 10.1016/j.bspc.2013.01.005
- [12] 李坤阳, 胡广书. 基于心电图分析的心律失常分类[J]. 清华大学学报(自然科学版), 2009, 49(3): 416
LI Kunyang, HU Guangshu. Arrhythmia classification based on ECG analysis [J]. Journal of Tsinghua University (Science and Technology), 2009, 49(3): 416. DOI: 10.16511/j.cnki.qhdx.2009.03.024
- [13] LI Taiyong, ZHOU Min. ECG classification using wavelet packet entropy and random forests[J]. Entropy, 2016, 18(8): 285. DOI: 10.3390/e18080285
- [14] KHAZAEI A, EBRAHIMZADEH A. Classification of electrocardiogram signals with support vector machines and genetic algorithms using power spectral features [J]. Biomedical Signal Processing and Control, 2010, 5(4): 252. DOI:10.1016/j.bspc.2010.07.006

- [15] ELHAJ F A, SALIM N, HARRIS A R, et al. Arrhythmia recognition and classification using combined linear and nonlinear features of ECG signals [J]. *Computer Methods and Programs in Biomedicine*, 2016, 127 (C): 52. DOI: 10.1016/j.cmpb.2015.12.024
- [16] KIRANYAZ S, INCE T, HAMILA R, et al. Convolutional Neural Networks for patient-specific ECG classification [C]// *Proceedings of the 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*. Milan, Italy: IEEE, 2015. DOI:10.1109/EMBC.2015.7318926
- [17] CHAUHAN S, VIG L. Anomaly detection in ECG time signals via deep long short-term memory networks [C]// *IEEE International Conference on Data Science & Advanced Analytics (DSAA)*. Paris, France: IEEE, 2015. DOI:10.1109/DSAA.2015.7344872
- [18] GU Jiuxiang, WANG Zhenhua, KUEN J, et al. Recent advances in convolutional neural networks [J/OL]. *Pattern Recognition*, 2015. <http://hgpu.org/?p=11941>
- [19] DONAHUE J, HENDRICKS L A, GUADARRAMA S, et al. Long-term recurrent convolutional networks for visual recognition and description [C]// *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Boston, MA: IEEE, 2015: 2625. DOI: 10.1109/CVPR.2015.7298878
- [20] PhysioNet. MIT-BIH arrhythmias database [EB/OL]. (2005-02-24). <http://www.physionet.org/physiobank/database/mitdb>
- [21] ACHARYA U R, OH S L, HAGIWARA Y, et al. A deep convolutional neural network model to classify heartbeats [J]. *Computers in Biology and Medicine*, 2017, 89: 389. DOI: 10.1016/j.complbiomed.2017.08.022
- [22] LIN Chuncheng, YANG Chunmin. Heartbeat classification using normalized RR intervals and morphological features [C]// *Proceedings of the International Symposium on Computer, Consumer and Control*. Taichung, Taiwan: IEEE, 2014. DOI: 10.1109/IS3C.2014.175
- [23] CAN Ye, COIMBRA M T, KUMAR B V K V. Arrhythmia detection and classification using morphological and dynamic features of ECG signals [C]// *Annual International Conference of the IEEE Engineering in Medicine and Biology*. Buenos Aires, Argentina: IEEE, 2010. DOI:10.1109/IEMBS.2010.5627645
- [24] MARTIS R J, ACHARYA U R, MANDANA K M, et al. Cardiac decision making using higher order spectra [J]. *Biomedical Signal Processing and Control*, 2013, 8(2): 193. DOI: 10.1016/j.bspc.2012.08.004

(编辑 张 红)

(上接第 60 页)

- [6] 朱胜庭, 朱大奇, 邓志刚. 多新息最小二乘法辨识水下机器人动力学模型 [J]. *系统仿真学报*, 2013, 25(6): 1399
ZHU Shengting, ZHU Daqi, DENG Zhigang. Identification of underwater vehicle dynamic model using multi-innovation least squares algorithm [J]. *Journal of System Simulation*, 2013, 25(6): 1399. DOI:10.16182/j.cnki.joss.2013.06.050
- [7] CORTES C, VAPNIK V. Support-vector networks [J]. *Machine Learning*, 1995, 20(3): 273. DOI:10.1007/BF00994018
- [8] ISA D, LEE L H, KALLIMANI V P, et al. Text document preprocessing with the Bayes formula for classification using the support vector machine [J]. *IEEE Transactions on Knowledge and Data Engineering*, 2008, 20(9): 1264. DOI: 10.1109/TKDE.2008.76
- [9] 邴其春, 龚勃文, 杨兆升, 等. 一种组合核相关向量机的短时交通流局域预测方法 [J]. *哈尔滨工业大学学报*, 2017, 49(3): 144
BING Qichun, GONG Bowen, YANG Zhaosheng, et al. A short-term traffic flow local prediction method of combined kernel function relevance vector machine [J]. *Journal of Harbin Institute of Technology*, 2017, 49(3): 144. DOI:10.11918/j.issn.0367-6234.2017.03.023
- [10] 徐锋, 邹建建, 徐小卡, 等. 基于支持向量机的船舶操纵运动黑箱建模 [J]. *北京航空航天大学学报*, 2013, 39(11): 1553
XU Feng, ZOU Zaojian, XU Xiaoka, et al. Black-box modeling of ship manoeuvring motion based on support vector machines [J]. *Journal of Beijing University of Aeronautics and Astronautics*, 2013, 39(11): 1553. DOI:10.13700/j.bh.1001-5965.2013.11.026
- [11] KENNEDY J, EBERHART R. Particle swarm optimization [C]// *Proceedings of the International Conference on Neural Networks*. Perth, WA: IEEE, 1995: 488968. DOI: 10.1109/ICNN.1995.488968
- [12] 杨维, 李歧强. 粒子群优化算法综述 [J]. *中国工程科学*, 2004, 6(5): 87
YANG Wei, LI Qiqiang. Survey on particle swarm optimization algorithm [J]. *Engineering Science*, 2004, 6(5): 87. DOI:10.3969/j.issn.1009-1742.2004.05.018
- [13] KIM T H, MARUTA I, SUGIE T. Robust PID controller tuning based on the constrained particle swarm optimization [M]. Tarrytown, NY: Pergamon Press, Inc. 2008. DOI: 10.1016/j.automatica.2007.08.017
- [14] GAING Z L. A particle swarm optimization approach for optimum design of PID controller in AVR system [J]. *IEEE Transactions on Energy Conversion*, 2004, 19(2): 384. DOI:10.1109/TEC.2003.821821
- [15] FOSSEN T I. Handbook of marine craft hydrodynamics and motion control [M]. New York: Wiley, 2011
- [16] DO K D, PAN Jie. Control of ships and underwater vehicles [J]. London: Springer, 2009. DOI:10.1007/978-1-84882-730-1
- [17] SMOLA A J, SCHOLKOPF B. A tutorial on support vector regression [J]. *Statistics and Computing*, 2004, 14(3): 199. DOI:10.1023/B:STCO.0000035301.49549.88
- [18] BOYD S, VANDENBERGHE L. Convex optimization [M]. Cambridge: Cambridge University Press, 2004
- [19] BRERETON R G, LLOYD G R. Support vector machines for classification and regression [J]. *Analyst*, 2010, 135(2): 230. DOI:10.1039/b918972f
- [20] BIAN Jingwei, XIANG Ji. QUUV: A quadrotor-like unmanned underwater vehicle with thrusts configured as X shape [J]. *Applied Ocean Research*, 2018, 78: 201. DOI:10.1016/j.apor.2018.06.017

(编辑 张 红)