

基于无监督学习的移动心电信号异常诊断研究

李 锋 谢嗣弘

(东华大学计算机科学与技术学院 上海 200000)

摘 要 针对心电信号异常诊断,提出了一种基于无监督学习的移动心电信号异常诊断方法。该方法利用层次聚类将心电数据进行分类,同时结合特征量的优先级诊断分析法,有效避免了因移动心电信号的数据量过大而产生爆炸的时间复杂度和空间复杂度的问题。最后,通过心电信号实例验证了所提方法具有良好的可靠性和运行效率。

关键词 心电信号,异常诊断,无监督学习,层次聚类

中图分类号 TP181 文献标识码 A

Study on Abnormal Diagnosis of Moving ECG Signals Based on Unsupervised Learning

LI Feng XIE Si-hong

(Department of Computer Science and Technology, Donghua University, Shanghai 200000, China)

Abstract To diagnosis the abnormal mobile ECG signals, a method based on unsupervised learning was proposed. The ECG data is classified by hierarchical clustering, and by combining the priority diagnosis method of the feature quantity, the complexity of time and the complexity of space consuming are effectively reduced. At last, the analysis of the examples verifies the methods of this paper.

Keywords ECG signals, Abnormal diagnosis, Unsupervised learning, Hierarchical clustering

心电图(ECG-Electrocardiogram)信号已经成为现代医疗临床实践中诊断心脏疾病的参考标准。而传统的人工心电图分析手段主要是临床心电诊断,这对于短时间的心电图分析具有较高的可靠性和实时性,但是面对普通人的日常心电监护时显得力不从心。躯感网的发展使得人们可以长时间收集个体的心电数据,通过对这些数据的分析,在无专业医学监督的情况下发现心电信号的异常,从而实现传统医学无法实现的保健和疾病预判功能,因此它具有非常重大的意义。

本课题研究的重点是利用无监督学习技术在躯感网中实现无医学监督下的人体异常状态判定,使其在收集数据的同时通过自我学习而拥有模式识别的能力。

心电信号的自动识别一直为各方所关注。Silipo R 等人^[1]提出了人工神经网络(ANN)的心电信号分类方法。汤征等人^[2]提出了结合心拍模板分类法与QRS波形态特征对房性早搏和室性早搏心拍进行分类的方法。赵毅等人^[3]设计并训练了一种使用 Levenberg-Marquardt 算法改进的 BP 神经网络,利用此网络检测并分类多种心律失常症状。Benali R 等人^[4]针对正常窦性心律节拍和 4 类异常心律节拍(左束支传导阻滞、右束支传导阻滞、房性早搏、室性早缩)提出了小波变换结合神经网络的分类方法。Shen C P 等人^[5]提出了支持向量机(SVM)结合 K-means 聚类算法的方法,对 100000 个心电样本进行分类。关于 SVM 的应用,韩君泽^[6]提出了基于支持向量机的心电分类算法。Lagerholm M 等人^[7]提出了基于自组织神经网络的心电信号无监督算法,以 MIT-BIH

Arrhythmia Database 数据库心电节拍为数据集,取得了明显的分类效果。De Chazal P 等人^[8]提出了基于形态学的心电信号分类算法,对 3 种心电节拍(正常心拍、心室异常、室上性异常)进行分类,平均分类精度达到了 75.9%。张菲菲和张征^[9]提出了一种自动检测心电异常的方法,该方法将待检测心电图与正常心电模板进行模板匹配,依据相关系数判断两者的匹配度,进而判断心电图是否存在异常。这些研究大多需要利用标签数据,通过大量的先期有监督学习来实现分类;或者通过对一般经典数据的总结,设计相关算法和参数,以达到分类的目的。目前在各种研究中缺乏一些能针对不同个体,并根据个体的特点通过自我无监督学习实现心电的异常判定的方案。

本文作者所在课题组一直从事躯感网和人工智能的研究,已开发出一种可穿戴的移动心电设备^[10-11],并在《心电异常波形智能诊断技术的研究和实现》《异常心电图的自动分析与诊断》《一种基于几何特征的 ECG 波形识别算法》中提出了一种基于几何特征和语义特征的心电图自动诊断方法^[12-14],完成了对移动心电数据的采集和特征的提取。本文主要利用层次聚类算法,提出了一种基于无监督学习的心电信号异常诊断方案,从而在无医学监督的情况下完成对个体心电异常的诊断。

1 基于层次聚类算法的心电信号异常诊断

无监督学习通过对无标签训练样本进行学习来发现数据

本文受上海市自然科学基金(16ZR1401100)资助。

李 锋(1969—),男,博士,教授,主要研究领域为深度学习、躯干网络,E-mail: lifeng@dhu.edu.cn;谢嗣弘(1988—),男,硕士,主要研究领域为模式识别、深度学习,E-mail: xsh003@126.com。

的内在性质,挖掘其潜在规律,为进一步的数据分析提供基础。在此类学习任务中,研究较多、应用较广的方法是“聚类”^[15]。

聚类领域中已有大量成熟的聚类算法,处理实际问题时选择哪一种聚类算法取决于待处理的数据类型、聚类目的及所涉及的应用领域。按照初始设定、算法策略和度量方式等方面的不同,聚类算法可以划分为:基于划分的方法、基于层次的方法、基于网格和密度的方法和基于模型的方法^[16]。

1.1 层次聚类

层次聚类(Hierarchical Clustering)算法试图在不同层次对数据集进行划分,从而形成树形的聚类结构,所以也被称为树形聚类算法。根据形成层次方式的不同,它可以被细分为凝聚聚类算法和分裂聚类算法。

凝聚聚类算法是一种自底向上的聚类算法。在聚类的开始阶段,它将每个样本对象作为一个单独的类簇,然后依据一定的度量准则相继地合并相近的类簇。当所有的类簇合并为一个类(层次的最上层)或者该聚类算法达到了一个给定的条件时,该算法终止^[17]。

分裂聚类算法与凝聚聚类算法的思维相反,它是一种自顶向下的聚类算法^[18]。在聚类的开始阶段,它将所有的样本对象归于一个整体的类簇,然后依据度量准则相继地将一个大类分裂为更小的类簇。该算法在所有样本对象都自成一个单独的类簇或者达到预设的条件时终止。

本文采用凝聚聚类算法,在算法迭代时找出距离最近的两个类簇并进行合并,直至达到预设的近似度距离。本文的关键是如何计算类簇之间的距离。实际上,每个类簇就是一个样本集合,因此只需要计算出关于集合的某种距离即可。例如,给定类簇 A_i 与 B_j ,可以通过以下公式来计算距离^[19]。

最小距离:

$$d_{\min}(A_i, B_j) = \min_{x \in A_i, y \in B_j} \text{dist}(x, y) \quad (1)$$

最大距离:

$$d_{\max}(A_i, B_j) = \max_{x \in A_i, y \in B_j} \text{dist}(x, y) \quad (2)$$

平均距离:

$$d_{\text{avg}}(A_i, B_j) = \frac{1}{|A_i| |B_j|} \sum_{x \in A_i} \sum_{y \in B_j} \text{dist}(x, y) \quad (3)$$

其中, $\text{dist}(x, y)$ 表示点 x 与点 y 之间的距离。最小距离和最大距离分别由两个类簇的最近样本和最远样本决定,而平均距离则由两个簇的所有样本共同决定。本文采用基于最小距离法的层次聚类算法:设数据集 D 由 m 个 x 维度的数据点 d_i 组成, $D = \{d_1, d_2, d_3, \dots, d_{m-1}, d_m\}$, C 为类簇 $C_1, C_2, C_3, \dots, C_{n-1}, C_n$ 的集合。 $Q(C_i)$ 为簇 C_i 的代表点集合,即 $Q(C_i) = \{r_1, r_2, \dots, r_{p-1}, r_{p_i}\}$, 其中 $p_i \leq \theta$, θ 为最大类簇代表点的数量。 $\text{dist}(C_i, C_j)$ 为簇 C_i 与簇 C_j 之间的最小距离,聚类簇距离度量的标准值为 d 。

Step1 根据数据集中每个向量 d_i , 创建各自的簇 C_i 。则初始化时生成类簇集合 $C = \{C_1, C_2, C_3, \dots, C_{n-1}, C_n\}$, $C_i = \{d_i\}$, $Q(C_i) = \{d_i\}$;

Step2 遍历簇集 C , 计算 $\text{dist}(C_i, C_j)$, 若 $\text{dist}(C_i, C_j) \geq d$, 终止执行;

Step3 合并类簇 C_i, C_j ;

Step4 重复执行 Step2 和 Step3, 直至算法执行完成。

1.2 心电信号特征量

心电的异常诊断通常依据心电图的特征量,其主要分为几何特征量和时域特征量。几何特征量表示特征波的幅度值,例如 R 波高度、T 波高度等,本文不再详细阐述^[20]。通常医生诊断时参照的时域特征量主要包括 RR 间期、PR 间期、QRS 间期、QT 间期、QTC 间期,如图 1 所示。




图 1 典型心电波形图

图 1 中,RR 间期指相邻两个特征波群 R 波之间的时间;PR 间期指同一波群中 P 波终点至 Q 波起点的时间;QRS 间期指同一波群中 Q 波起点至 S 波终点的时间;QT 间期指同一波群中 Q 波起点至 T 波终点的时间。QTC 间期由 QT 间期与 RR 间期计算所得,通常采用以下公式。

Bazetts 公式:

$$QTC = \frac{QT}{RR^{0.5}} \quad (4)$$

Fridericia 公式:

$$QTC = \frac{QT}{RR^{0.33}} \quad (5)$$

由于目前的心电诊断往往直接参照 QTC 间期,而省略了 QT 间期,因此本文实验只采用了 RR 间期、PR 间期、QRS 间期、QTC 间期共 4 个时域特征进行分析。

2 异常监测

2.1 心电数据集介绍

本文实验数据来自于课题组收集的用户数据集,共计 1448 条记录。每条数据记录了测试用户在 2 分钟内的 RR 间期值、PR 间期值、QRS 间期值、QTC 间期值。根据测试用户的情况,为验证算法的有效性,通过人工方式将其标注成两类,其中正常类 1277 条,非正常类 171 条(这里的类别划分是基于测试用户自身的生理状况,并非医学上的标准规则,即正常类是指测试用户通常的生理值,非正常类是指测试用户不常见的生理值)。部分实验数据的详细信息如表 1 所列。

表 1 部分实验数据集

样本号	RR 间期/s	PR 间期/s	QRS 间期/s	QTC 间期/s
0	0.129786475	0.122470162	0.091547457	0.382785191
1	0.129723613	0.123253032	0.09080758	0.386041326
2	0.129884037	0.162607619	0.090975526	0.385658239
3	0.161371694	0.125266632	0.089629778	0.386459525
4	0.139465683	0.163715492	0.091172711	0.3828546674

2.2 心电信号层次聚类

为了提高心电信号的诊断效率,根据医学知识以及医生的建议,先将心电信号的 4 个时域特征依据其重要性建立优先级,按照 RR, PR, QRS 和 QTC 顺序进行层次聚类。聚类流程图如图 2 所示。




图2 基于无监督学习的心电异常诊断流程图

根据图2,首先对心电信号RR间期进行层次聚类,根据用户通常生理值以及医生的建议,设定初始聚类的RR间期中心值和阈值 d 。然后进行本阶段的层次聚类,若聚类结果显示在RR间期正常区间内还存在其他类簇,则表明该用户在RR间期存在异常情况,系统输出检测到的异常样本,至此第一阶段的聚类结束。随后,进行第二阶段的层次聚类,本阶段的数据集是在第一阶段的正常数据集的基础上加入了PR间期特征量,即该数据集是由RR间期、PR间期二维数据组成,然后重新设定聚类度量标准 d ,进一步挖掘异常的心电记录。以此类推,直至心电信号的4个时域特征量都参与了层次聚类分析,整个心电信号诊断流程结束。每一个阶段的流程将在下文详细阐述。

2.2.1 基于RR间期的层次聚类

本阶段数据集共有1448条样本,每条样本记录了某一时间段测试用户心电信号RR间期的时域特征值。在本阶段采用基于最小距离法的心电信号层次聚类算法,此时数据集 D 由1448个数值为PR间期值的数据点 d_i 组成, $D = \{d_1, d_2, d_3, \dots, d_{1447}, d_{1448}\}$,且设定聚类距离标准为 d 。然后进行层次聚类,依次计算每两个类簇之间的最小距离 $dist(C_i, C_j)$,若满足 $dist(C_i, C_j) \leq d$,则合并类簇 C_i 和 C_j ;反之,则终止算法执行。其聚类效果如图3所示。




图3 基于RR间期的聚类情况

其中,“×”代表测试用户的正常生理值,算法正确判定出1300条。“•”代表测试用户的异常生理值,有148条。

2.2.2 基于RR间期、PR间期的层次聚类

此阶段的数据集是在上一轮1300条正常数据集的基础上加入了PR间期数值。此时,数据集 D 由1300个二维的数据点 d_i 组成,即 $D = \{d_1, d_2, d_3, \dots, d_{1299}, d_{1300}\}$ 。其聚类效果如图4所示。




图4 基于RR间期、PR间期的聚类情况

如图4所示,横坐标表示心电信号的RR间期值,纵坐标表示心电信号的PR间期值。其中,“×”代表测试用户正常生理记录,算法正确预测出1268条。“•”代表测试用户异常生理记录,算法判定出32条。

2.2.3 基于RR间期、PR间期、QRS间期的层次聚类

基于上一阶段判断为正确的1268条正常数据,再加入QRS间期值,数据集由心电信号的RR间期、PR间期、QRS间期的数值组成,判定效果如图5所示。




图5 RR间期、PR间期、QRS间期的聚类情况

如图5所示,3个空间坐标轴分别表示心电信号的RR间期值、PR间期值、QRS间期值。其中,位于曲面 L 左侧的“•”代表测试用户正常记录,共1255条。位于 L 曲面右侧的“•”点代表测试用户异常生理记录,共13条。

2.2.4 基于RR间期、PR间期、QRS间期、QTC间期的层次聚类

数据集 D 在上一阶段聚类后的正常样本的基础上新加入QTC间期值,每条记录具有四维属性,分别代表心电信号的RR间期、PR间期、QRS间期、QTC间期数值。同理,采用基于最小距离的层次聚类进行无监督聚类,其实验结果如图6所示。

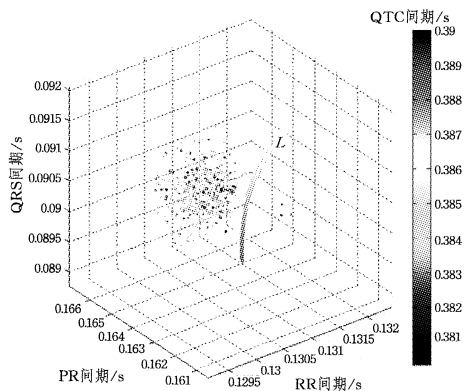


图6 RR间期、PR间期、QRS间期、QTC间期的聚类情况

图6中,3个空间坐标分别代表心电信号的RR间期值、

PR 间期值、QRS 间期值,色彩值代表心电信号的 QTC 间期值;位于曲面 L 左侧且色彩数值在 0.387 以下的点代表测试用户正常生理记录。位于曲面 L 右侧的点代表测试用户心电信号异常生理记录,有 5 条。

整个实验数据的分析结果如表 2 所列。

表 2 分类结果

	实际正常类	实验判定	异常类	实验判定
RR	1307	1300	141	148
RR+PR	1270	1268	30	32
RR+PR+QRS	1256	1255	14	13
RR+PR+QRS+QTC	1251	1250	4	5

表 2 中,RR 指数数据集基于 RR 间期一个心电时域特征的层次聚类;RR+PR 指数数据集基于 RR 间期、PR 间期两个心电时域特征的层次聚类;RR+PR+QRS 指数数据集基于 RR 间期、PR 间期、QRS 间期 3 个心电时域特征的层次聚类;RR+PR+QRS+QTC5 指数数据集基于 RR 间期、PR 间期、QRS 间期、QTC 间期 4 个心电时域特征的层次聚类。

3 实验分析

3.1 实验评价标准

本文采取传统的准确率(CA)、兰德指数(RI)、F 值(F)来评价算法性能。

(1)准确率(CA)

$$CA = \frac{A}{B} \quad (6)$$

其中, A 表示测试结果正确的样本数目, B 表示测试样本的总数目。

(2)兰德指数(RI)

$$RI = \frac{TP + TN}{TP + FP + FN + TN} \quad (7)$$

其中, TP 表示聚类预测为正常类,实际为正常类; FP 表示聚类预测为正常类,实际为异常类; FN 表示聚类预测为异常类,实际为正常类; TN 表示聚类预测为异常类,实际为异常类。

(3)F 值(F)

$$P = \frac{TP}{TP + FP} \quad (8)$$

$$R = \frac{TP}{TP + FN} \quad (9)$$

$$F = \frac{2PR}{P + R} \quad (10)$$

3.2 实验评价

3.2.1 算法分析

对 10 人 120 小时的数据进行分析,得到的实验结果评价如表 3 所列。

表 3 采用层次聚类算法的心电信号特征量无监督聚类评价

	准确率(CA)	兰德指数(RI)	F 值
RR	0.996	0.998	0.997
RR+PR	0.998	0.997	0.998
RR+PR+QRS	0.997	0.998	0.998
RR+PR+QRS+QTC	0.997	0.999	0.998

为了验证算法的可行性,本文选取上述关于 RR, PR, QRS, QTC 4 个间期的实验数据和检测结果与前人研究的相

关算法的结果进行了比较,结果如表 4 所列。

表 4 本文算法检测效果与其他算法的比较

方法	准确率(CA)	兰德指数(RI)	F 值
层次聚类	0.997	0.999	0.998
自组织神经网络	0.787	0.851	0.834
SVM+K-means	0.911	0.924	0.963
人工神经网络	0.931	0.926	0.928
形态学	0.759	0.741	0.752

3.2.2 运行分析

本文根据心电信号时域特征优先级进行异常诊断分析,使得整个心电信号异常诊断的效率得到一定幅度的提高。经本算法验证,异常数据集中的绝大部分样本只需低维度特征验算即可识别,如表 5 所列,91%的异常数据只参与了二维以下的聚类,在空间复杂度和时间复杂度上得到明显优化。在动态心电检测中,由于系统产生的心电数据量较大,采用这种机制的无监督诊断可以在一定程度上降低整个检测系统的复杂度,提高其诊断效率与性能。其诊断效率分析如表 5 所列。

表 5 诊断效率分析表

层次聚类阶段	正确预测出的异常记录数量	预测比例/%
RR	141	75.0
RR+PR	30	15.95
RR+PR+QRS	13	6.91
RR+PR+QRS+QTC	4	2.13
合计	188	

结束语 本文采用的层次聚类算法经过了真实心电信号数据的验证,其对大部分的心电信号特征数据的聚类效果明显,但是仍然存在误判的可能性,且聚类的时间复杂度依然很高。因此,针对心电信号无监督异常诊断的相关研究仍然有很大的提升空间,对算法进行进一步改进以适应心电数据的特殊类型。此次实验只是针对心电信号众多特征中的 4 种特征进行了聚类分析,课题组后续的工作可以深入展开更多基于无监督学习的心电信号异常诊断的研究。

参考文献

- [1] SILIPO R, MARCHESI C. Artificial neural networks for automatic ECG analysis[J]. IEEE Transactions on Signal Processing, 1998, 46(5): 1417-1425.
- [2] 汤征. 引入异常心电节律分析的心拍分类算法研究[D]. 杭州: 浙江大学, 2008.
- [3] 赵毅. 基于小波分析和神经网络的异常心电信号分类研究[D]. 太原: 太原理工大学, 2015.
- [4] BENALI R, REGUIG F B, SLIMANE Z H. Automatic Classification of Heartbeats Using Wavelet Neural Network[J]. Journal of Medical Systems, 2012, 36(2): 883-892.
- [5] SHEN C P, KAO W C, YANG Y Y, et al. Detection of cardiac arrhythmia in electrocardiograms using adaptive feature extraction and modified support vector machines[J]. Expert Systems with Applications, 2012, 39(9): 7845-7852.
- [6] 韩君泽. 心电信号自动检测与诊断方法的研究[D]. 哈尔滨: 哈尔滨工业大学, 2013.
- [7] LAGERHOLM M, PETERSON C, BRACCINI G, et al. Clustering ECG complexes using hermite functions and self-organizing maps[J]. IEEE Trans Biomed Eng, 2000, 47(7): 838-848.

从表 1 和表 2 中看到,当预测的天数固定时,并不是参与训练的天数越多,精度就越高;相反,参与训练的天数越多,预测的精度越低,这是因为考虑了任务间的相关性后,若每组中训练数据的天数越多,则每个任务之间相似的数据就越少,即任务间的相关性越小,因此就会出现实验 1 的情况,精度会下降很多。

从表 3 中可以看出,当已知天数固定时,预测未来的天数越少,预测的精度越高,需要的时间也就越多。

从图 1 中可以看到,股票上证指数的波动非常大,在预测一组数据时并不是选取的天数越多,预测数据就越准确,间隔几天的数据之间的相关性会大大降低,因此在基于多任务的股票学习中, p 和 q 的取值要根据实际情况来确定。

结束语 股票市场结构复杂,影响因素众多且极不稳定,运用现阶段的手段预测股票价格的变化趋势无疑需要经受各种考验。本文采用多任务的方式进行回归预测研究,并将所提方法与支持向量机 SVM 方法进行了对比,结果表明本方法的精度提高了约 10 倍。但是预测新任务时,很难得到任务间的相关性的确定值,而在多任务方法中,相关性通过学习而得到,因此在后续的研究中,我们将进一步考虑输出间的相关性;同时,在股票预测中,通过回归预测只能得到大致的走向,但实际的升降准确率并不高,即如何提高分类的准确性也是需要进一步研究的内容。

参 考 文 献

- [1] BIELZA C, LI G, LARRANAGA P. Multi-dimensional classification with Bayesian networks[J]. International Journal of Approximate Reasoning, 2011, 52: 705-727.
- [2] TIBSHIRANI R. Regression shrinkage and selection via the lasso[J]. Journal of the Royal Statistical Society, 2011, 73(3): 267-288.
- [3] ZHOU J, CHEN J, YE J, MALSAR. Multi-task Learning via Structural Regularization[D]. Arizona State University, 2012.
- [4] 肖瑞. 不确定性时间序列的降维与相似性匹配研究[D]. 上海: 东华大学, 2014.
- [5] 王琼瑶. 基于改进的支持向量机技术在股票短期价格预测中的应用[D]. 重庆: 重庆交通大学, 2015.
- [6] NG A. Stanford Engineering Everywhere CS229 lecture-Machine Learning[OL]. <https://see.stanford.edu/course/cs229>.
- [7] MURPHY K P. Machine Learning: A Probabilistic Perspective [M]. MIT Press, 2012.
- [8] BECK A, TEOULLE M. A fast iterative shrinkage-thresholding algorithm for linear inverse problems[J]. Siam Journal on Imaging Sciences, 2009, 2(1): 183-202.
- [9] HAN L, ZHANG Y. Multi-stage multi-task learning with reduced rank[C]//Proceedings of the Thirtieth AAAI Conference on Artificial Intelligence(AAAI-16). 2016.
- [10] LEE G, YANG E, HWANG S J. Asymmetric multi-task learning based on task relatedness and loss[C]//Proceedings of the 33rd International Conference on Machine Learning. New York, NY, USA, 2016: 230-238.
- [11] 吴喜之, 刘苗编. 应用时间序列分析: R 软件陪同[M]. 北京: 机械工业出版社, 2014.
- [12] TASKAR B. Learning structured prediction models: A large margin approach[D]. Stanford University, 2004.
- [13] JOACHIMS T, HOFMANN T, YUE Y S, et al. Predicting Structured Objects with Support Vector Machines[J]. Communications of the ACM, 2009, 52(11): 97-104.
- [14] JOACHIMS T, FINLEY T, YU C N J. Cutting-plane training of structural svms[J]. Machine Learning, 2009, 77(1): 27-59.
- [15] HAGAN M T, DEMUTH HB, BEALE M H, et al. Neural network design[M]. PWS Publishing Company Boston, 1996.
- [16] MAGERMAN D M. Statistical decision-tree models for parsing [C]//Proceedings of the 33rd Annual Meeting on Association for Computational Linguistics. 1995: 276-283.
- [17] DINUZZO F, ONG C S, GEHLER P, et al. Learning output kernels with block coordinate descent[C]//Proceedings of the 28th Annual International Conference on Machine Learning. Bellevue, WA, USA, 2011.
- [18] DINUZZO F, FUKUMIZU K. Learning low-rank output kernels [J]. Journal of Machine Learning Research Proceedings Track , 2011(20): 181-196.
- [19] ZHANG M L, ZHOU Z H. A Review on Multi-Label Learning Algorithms[J]. IEEE Transactions on Knowledge & Data Engineering, 2014, 26(8): 1819-1837.
- [14] 吴海峰. 心电异常波形智能诊断技术的研究和实现[D]. 上海: 东华大学, 2014.
- [15] 伍育红. 聚类算法综述[J]. 计算机科学, 2015, 42(S1): 491-499, 524.
- [16] 刘园. 基于划分和层次的聚类算法关键技术研究[D]. 西安: 西安理工大学, 2014.
- [17] 张振亚, 程红梅, 王进, 等. 面向凝聚式层次聚类算法实现的矩阵存储数据结构研究[J]. 计算机科学, 2006, 33(1): 14-17.
- [18] 任江涛, 吴海建, 吴向军, 等. 一种基于遗传算法的分裂式层次化聚类算法[J]. 计算机应用, 2005, 25(11): 2618-2620.
- [19] 张峻玮, 杨洲. 一种基于改进的层次聚类的协同过滤用户推荐算法研究[J]. 计算机科学, 2014, 41(12): 176-178.
- [20] 冷莉华, 郑智捷. 窦性心律失常心电图序列的可视化研究[J]. 计算机科学, 2016, 43(S2): 183-185.

(上接第 71 页)

- [8] DE C P, O'DWYER M, REILLY R B. Automatic classification of heartbeats using ECG morphology and heartbeat interval features[J]. IEEE Transactions on Bio-medical Engineering, 2004, 51(7): 1196-1206.
- [9] 张菲菲, 张征. 心电异常自动检测的研究[J]. 电脑知识与技术, 2016, 12(4): 197-199.
- [10] 李锋, 徐涵. 微型便携式心电监护仪的实现[J]. 电子产品世界, 2012, 19(12): 52-54.
- [11] 程坤. 穿戴式躯域网系统的设计与实现[D]. 上海: 东华大学, 2015.
- [12] 李锋, 吴海峰, 张能. 异常心电图的自动分析与诊断[J]. 北京生物医学工程, 2015, 34(2): 166-174.
- [13] 李锋, 陈美丽. 一种基于几何特征的 ECG 波形识别算法[J]. 北京生物医学工程, 2015, 34(3): 261-266.