

基于核稀疏编码的阵发性房颤检测

刘明 孟宪辉 熊鹏 刘秀玲*

(河北大学电子信息工程学院 保定 071002)

(河北省数字医疗工程重点实验室 保定 071002)

摘要: 阵发性房颤(PAF)是一种具有偶发性的心律失常,其较高的漏检率导致心脏相关疾病的增加。该文提出了一种基于核稀疏编码的自动检测方法,可以仅根据较短RR间期数据识别PAF发作。该方法采用特殊几何结构来分析数据高维特性,通过计算协方差矩阵作为特征描述子,找到蕴含在数据中的黎曼流形结构;然后基于Log-Euclid框架,利用核方法将流形空间映射到高维可再生核希尔伯特空间,以获取更准确的稀疏表示来快速识别PAF。经麻省理工学院-贝斯以色列医院房颤数据库验证,获得98.71%的敏感性、98.43%的特异度和98.57%的总准确率。因此,该研究对检测短暂发作的PAF有实质性的改善,在临床监测和治疗方面显示出良好的潜力。

关键词: 阵发性房颤;协方差描述子;黎曼流形;核稀疏编码

中图分类号: TP399

文献标识码: A

文章编号: 1009-5896(2020)07-1743-07

DOI: 10.11999/JEIT190582

Detection of Paroxysmal Atrial Fibrillation Based on Kernel Sparse Coding

LIU Ming MENG Xianhui XIONG Peng LIU Xiuling

(College of Electronic and Information Engineering, Hebei University, Baoding 071002, China)

(Key Laboratory of Digital Medical Engineering of Hebei Province, Baoding 071002, China)

Abstract: Paroxysmal Atrial Fibrillation (PAF) is a kind of accidental arrhythmia, and its high missed detection rate leads to the increase of heart-related diseases. An automatic detection method is proposed based on kernel sparse coding, which can identify PAF attacks based only on short RR interval data. A special geometric structure is presented to analyze the high-dimensional characteristics of the data, and the covariance matrix is calculated as a feature descriptor to find the Riemannian manifold structure contained in the data; Based on the Log-Euclidean framework, a manifold method is used to map the manifold space to a high-dimensional renewable kernel Hilbert space to obtain a more accurate sparse representation to identify quickly PAF. After verification by the Massachusetts Institute of Technology-Beth Israel Hospital atrial fibrillation database, the sensitivity is 98.71%, the specificity is 98.43%, and the total accuracy rate is 98.57%. Therefore, this study has a substantial improvement in the detection of transient PAF and shows good potential for clinical monitoring and treatment.

Key words: Paroxysmal Atrial Fibrillation(PAF); Covariance descriptor; Riemann manifold; Kernel sparse coding

收稿日期: 2019-08-01; 改回日期: 2020-03-04; 网络出版: 2020-03-27

*通信作者: 刘秀玲 liuxiuling121@hotmail.com

基金项目: 国家自然科学基金(61673158), 河北省自然科学基金(F2018201070), 河北省研究生创新资助项目(CXZZSS2019006), 河北省青年拔尖人才项目(BJ2019044)

Foundation Items: The National Natural Science Foundation of China (61673158), The Natural Science Foundation of Hebei Province (F2018201070), The Graduate Innovation Funding Project of Hebei Province (CXZZSS2019006), The Hebei Young Talent Project (BJ2019044)

1 引言

心房颤动(Atrial Fibrillation, AF)是最常见的持续性心律失常,其源自心房的不规则刺激。大多数房颤患者表现为阵发性房颤(Paroxysmal AF, PAF),也称间歇性房颤,偶尔发生,需要几分钟至几天才能自动终止^[1]。通常情况下,PAF患者表现不出任何明显的临床症状,且发作频率是不确定的,所以静息短程心电图检查往往难以发现PAF,导致大多数早期容易治疗且复发率低的房颤病例没有及时诊断,进而演变为持续性房颤,并伴有心脏相关并发症^[2]。因此,长期的、持续的无创监测可提高检出率,但考虑到信号质量往往较差,开发出鲁棒的自动检测器以减少人工检查数据的时间是很重要的。

近年来,人们提出了许多不同的AF检测方法:大多数检测器以RR间期序列为出发点^[3-5],而少数检测器还涉及P波和f波形态的信息^[6]。然而,后一类检测器具有更高的计算要求,使得它们不适合在低功耗监测设备中实现。此外,f波频率极低且形态各异,使得获取特征的难度更大。但在基于RR间期的AF检测器中一个急需解决的问题是改善短暂(<30 s)阵发性房颤发作的检出率。近年来,文献^[7]设计了一个由异位拍频滤波、二叉神经抑制、RR间期不规则性表征和信号融合构成的检测器,方便了短暂房颤发作的检测。文献^[8]基于信息的相似性分析提出了一种集成方案,该方法为提高分类精度提供了定量信息。文献^[9]利用小波多尺度熵与支持向量机的方法,将小波分解和非线性分析相结合,从心律变异性(Heart Rhythm Variability, HRV)信号中提取特征参数并分析其量化指标。文献^[10]采用卷积神经网络和递归神经网络相结合的端到端深度学习模型,从RR间期序列段中自动提取高水平特征。尽管这些研究成果一定程度上提高了PAF的检出率,但仍需进一步全面提升检测器性能。

本文的目的是提出一种适用于动态检测系统,并能够精准地自动检测出早期较短阵发性房颤的方法。有研究表明,人类心脏动力学由迷走神经和交感神经两种相互竞争的复杂非线性作用驱动。通过对患者进行HRV分析,从自主神经功能方面探寻其房颤的发生和维持机制。对于这种固有噪声系统,使用不同滤波器对RR间期时间序列滤波可得到其不同生理特征,计算这些不同特征之间的协方差矩阵作为检测的特征描述子。协方差描述子最初是由Tuzel等人^[11]提出的,相比其他描述子能够表征不同视觉的特征和特征间的关系,且维数较低使

计算简单。此外,协方差矩阵自身具有的对称半正定性可诱导成一个非欧、弯曲的黎曼流形结构。近年来,已经成功地应用在目标跟踪、人脸识别、疾病检测和动作识别等领域,证明了样本空间用弯曲的黎曼流形表达,能够对样本给出更好的解释。文献^[12]赋予了黎曼空间一种仿射不变黎曼度量(Affine Invariant Riemannian Metric, AIRM),作为测地距离可将欧氏空间的经典方法应用在流形上,但公式比较复杂计算耗时。文献^[13]则提出Log-Euclid测度代替AIRM,将黎曼流形空间同构、同胚的等距映射到向量空间,避免了直接在黎曼流形上进行统计建模计算量大的问题。在Log-Euclid框架中,文献^[14]发展了基于Log-Euclid的核函数来刻画测地距离,以准确地估计重构误差,利用核方法将流形空间映射到高维可再生核希尔伯特空间(Reproducing Kernel Hilbert Space, RKHS),以解决协方差矩阵描述子的字典学习和稀疏表示问题。

基于此,本文提出了基于核稀疏编码的阵发性房颤检测方法。该方法仅使用较短RR间期数据窗口,数据简单不需要大内存缓冲区;使用协方差矩阵作为特征描述子,用较低维数的矩阵代表多个特征的自然融合,既捕获了空间性质又捕获了统计性质;考虑特征的特殊几何结构,利用核方法将数据映射到高维空间,可以更丰富地展示易于理解的数据分布;通过核稀疏编码得到的稀疏表示直接用来分类,无需分类器的设计与训练减少了对参数的依赖,泛化能力强。因此,本文提出的高精度、低虚警的阵发性房颤检测算法在长期心电监测中具有潜在的应用前景。

2 方法

心电信号具有大量的个体差异并受多种因素的干扰,导致其具有高维的复杂非线性特性,现有研究成果表明房颤可通过少数特征来识别^[3-10],但目前还没有找到有效方法。为了解决这个问题,本文提出基于协方差描述子与核稀疏编码的阵发性房颤检测方法。首先提取心电信号的RR间期序列,特征描述子定义为RR间期序列计算的协方差矩阵;在协方差描述子构成的黎曼流形上,可采用Log-Euclid度量创建对称正定核函数,然后通过核映射的方法将特征映射到高维RKHS;最后,采用稀疏编码的方法得到特征的字典原子库与稀疏表示,根据重建误差值得到最终分类结果。所提算法的总体流程如图1所示。

2.1 协方差矩阵

对于具有 m 维特征空间的输入向量 \mathbf{I} ,定义函数 $F(\mathbf{I}, x_i) = \mathbf{f}_i$,其中函数 F 可以是任何映射,比

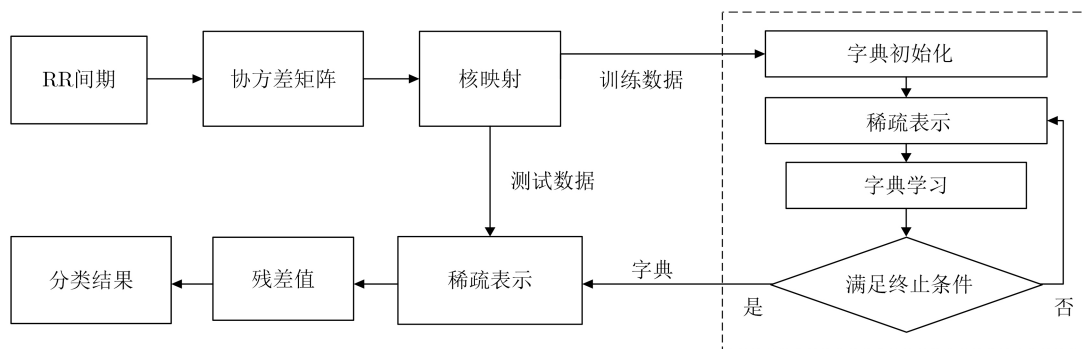


图1 PAF检测流程图

如梯度、滤波响应等。 $f_i \in R^m$ 是第*i*个元素的*m*维特征向量， x_i 是第*i*个元素的位置。对于给定区域R， $\{f_i\}_{i=1,2,\dots,r}$ 是区域R内的所有元素*m*维特征的集合， μ 为每维特征的均值。所以基于区域R的 $m \times m$ 协方差矩阵 X_R 为

$$X_R = \frac{1}{r-1} \sum_{i=1}^r (f_i - \mu)(f_i - \mu)^T \quad (1)$$

协方差矩阵通常是对称正定(Symmetric Positive Definite, SPD)矩阵，特征之间的变化由对角线元素表征，特征之间的相关性由非对角元素表征。SPD矩阵构成了一个李群为黎曼流形空间。本文使用Log-Euclid度量^[13]来描述SPD矩阵之间的相似性

$$d(X_1, X_2) = \|\lg(X_1) - \lg(X_2)\|_F \quad (2)$$

2.2 基于Log-Euclid核的稀疏表示与字典学习

流形空间 S_+^d 不是线性空间，不能进行传统的矩阵加法和标量矩阵乘法运算。由于SPD矩阵空间是一个完备的内积空间，文献^[13]中给出了Log-Euclid框架下的对数加法和标量对数乘法运算。因此，发展出了一个满足Mercer条件的广义Log-Euclid核族。这些Log-Euclid核函数描述了测地距离，可以有效地利用流形几何结构^[14]。因此，对于黎曼流形上的稀疏编码，可以利用Log-Euclid核函数将SPD矩阵映射到再生核希尔伯特空间上，并将流形上的“组合”作为希尔伯特空间中的线性组合。

2.2.1 稀疏表示

对于黎曼流形上的给定点 $X \in S_+^d$ ，黎曼字典 $B_i \in S_+^d, i = 1, 2, \dots, N$ 和一个表示SPD矩阵到RKHS的映射函数 $\varphi: \text{Sym}_+^d \rightarrow \text{RKHS}$ ，试找到一个稀疏向量 $\alpha \in R_N$ 将 $\varphi(X)$ 编码为 $\{\varphi(B_1), \varphi(B_2), \dots, \varphi(B_N)\}$ 的稀疏表示。这一过程被表述为LASSO问题的核版本

$$\min \left(\left\| \varphi(X) - \sum_{i=1}^N \alpha_i \varphi(B_i) \right\|_2^2 + \lambda \|\alpha\|_1 \right) \quad (3)$$

其中， λ 是正则化参数，并且在实验中根据经验设定为0.01。基于Log-Euclid框架^[14]中的内核函数，在RKHS中实现了LASSO问题的凸和内核形式，从而准确地测量重构误差。式(3)中的第1项可以以内核形式扩展为

$$\begin{aligned} & \left\| \varphi(X) - \sum_{i=1}^N \alpha_i \varphi(B_i) \right\|_2^2 \\ &= k(X, X) - 2 \sum_{i=1}^N \alpha_i k(X, B_i) \\ &+ \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j k(B_j, B_i) \end{aligned} \quad (4)$$

在核函数 $\|\varphi(X)\|_2 = 1$ 中， X 的稀疏表示式(3)可以改写为

$$\min_{\alpha \in R_N} \left(-2 \sum_{i=1}^N \alpha_i k(X, B_i) + \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j k(B_j, B_i) + \lambda \|\alpha\|_1 \right) \quad (5)$$

除定义 $k(X, B_i)$ 和 $k(B_j, B_i)$ 外，式(5)中的优化问题是凸的，并且类似于欧氏空间中的优化问题。因此，可以采用贪婪解或松弛解来获得稀疏编码^[15]。

2.2.2 字典学习

给定一组训练数据 $X_j, j = 1, 2, \dots, M$ ，字典原子库可以通过学习获得，使得它们具有更强的表示能力。学习问题可以表示为式(6)的函数最优化问题

$$\begin{aligned} & f(B_1, \dots, B_i, \alpha_j, \dots, \alpha_M) \\ &= \sum_{j=1}^M \left\| \varphi(X_j) - \sum_{i=1}^N \alpha_{j,i} \varphi(B_i) \right\|_2^2 + \lambda \|\alpha_j\|_1 \end{aligned} \quad (6)$$

其中 $\alpha_j = [\alpha_{j,1}, \alpha_{j,2}, \dots, \alpha_{j,N}]$ 代表 X_j 的稀疏向量。

采用类似于K-SVD的方法优化原子^[15]，基于核函数 κ 得到的偏导数为

$$\frac{\partial f}{\partial \mathbf{B}_r} = -2\beta \mathbf{B}_r^{-1} \left(\sum_{j=1}^M \alpha_{j,r} \kappa(\mathbf{B}_r, \mathbf{X}_j) (\lg(\mathbf{B}_r) - \lg(\mathbf{X}_j)) - \sum_{j=1}^M \sum_{i=1}^N \alpha_{j,r} \alpha_{j,i} (\lg(\mathbf{B}_r) - \lg(\mathbf{B}_j)) \right) \quad (7)$$

因此, 在李群中原子矩阵的更新公式为

$$\mathbf{B}_r = \exp \left(\lg(\mathbf{B}_r) + d_{B_r} \lg \left(\frac{-\partial f}{\partial \mathbf{B}_r} \right) \right) \quad (8)$$

2.3 房颤检测计算过程

接下来给出具体的计算过程:

步骤 1 计算协方差描述子: 对于每个RR间期序列 $R(n)$, 首先计算式(9)中的5维特征向量, 其中包括1阶2阶差分信息以及同为3点的最大值、最小值和高斯滤波器的响应值

$$\mathbf{f} = [\Delta R, \Delta^2 R, \max(R), \min(R), \text{Gauss}(R)] \quad (9)$$

根据式(1)计算每个 $R(n)$ 对应的 5×5 协方差描述子 \mathbf{X} 。

步骤 2 计算核函数: 由于高斯核表现出的优良特性, 本文采用文献[16]中的Log-Euclid高斯核进行核计算

$$k_g(\mathbf{X}_1, \mathbf{X}_2) = \exp(-\beta d(\mathbf{X}_1, \mathbf{X}_2)^2) \quad (10)$$

其中 $\beta = 0.6$ 为衰减因子。

步骤 3 构建代表AF和非AF的字典原子: 首先, 由训练数据采用K-means聚类算法得到初始字典; 然后固定字典, 求式(5)最优解得到最优稀疏表示; 再固定稀疏表示, 由式(8)来更新字典。以此迭代的更新优化, 直至目标函数式(6)的值达到最优或达到最大迭代次数。

步骤 4 计算测试样本的稀疏编码: 将上一步构建的两类字典组合成一个大字典, 由式(5)求测试数据在大字典上的最优稀疏表示向量。

步骤 5 重建残差判断类别: 根据稀疏向量 α , 可计算测试样本 \mathbf{X} 的残差值为

$$\varepsilon_c = -2\kappa(\mathbf{X}, \mathbf{B}_c)\alpha + \alpha^T \kappa(\mathbf{B}_c, \mathbf{B}_c)\alpha \quad (11)$$

式中 \mathbf{B}_c 表示 c 类的所有字典原子。残差值最小的原子类别即为待测样本所属类别, 即

$$c^* = \arg \min_c \varepsilon_c \quad (12)$$

3 实验

3.1 数据库

本研究所使用的ECG信号取自麻省理工学院-贝斯以色列医院(Massachusetts Institute of Technology-Beth Israel Hospital, MIT-BIH)房颤数据

库(AFDB: <http://www.physionet.org/physiobank/database/afdb/>)^[17]。AFDB包括25例阵发性房颤患者的心电图记录(持续时间约为10 h), 采样频率为250 Hz, 共包含 10^6 以上次心搏, 其中43%发生在AF期间。本实验只使用其中23条记录, 排除记录04936和05091, 因为这些记录包含不正确的注释。

图2显示了来自MIT-BIH AFDB的PAF患者的RR间期时间序列。视觉检查显示, 随着房颤的发生, 心率发生显著变化, 房颤发作的RR间期波动幅度明显高于非房颤期。




图2 PAF患者ECG记录的RR间期时间序列

3.2 数据预处理

从ECG信号中提取RR间期的常用方法为检测QRS波群。本文采用Pan-Tompkins算法进行R峰检测, 该算法能够减少干扰, 避免错误检测。由检测到的R峰位置计算RR间期时间序列

$$\text{RR} = \frac{R_p(n+1) - R_p(n)}{f_s} \quad (13)$$

其中, $R_p(n)$ 是第 n 个R峰的位置, f_s 是心电信号采样频率。

根据PhysioNet数据库上提供的注释选出AF段与非AF段, 随机留出AF和非AF的百分比作为训练数据, 其余为测试数据。重复此步骤5次, 以便生成具有不同训练和测试数据的5个数据集。分别从训练和测试数据以不同的观察窗口 n 截取RR间期子序列进行实验。

3.3 实验结果分析

在本文的实验中, 有2个可调参数: 字典原子总数 N 和观察窗口 n 。实验中选取 N 从40~120, 选取 n 从16~64。本文目的是寻找最佳的参数设置和敏感性不同的参数设置。为了评价算法的预测性能, 计算了敏感性(Sensitivity, Se)、特异度(Specificity, Sp)和总体准确率(Accuracy, Acc), 并进行了反复交叉验证。Se定义为(真阳性)/(真阳性+假阴性), Sp定义为(真阴性)/(真阴性+假阳性), Acc定义为(真阴性+真阳性)/(真阴性+真阳性+假阴性+假阳性)。

表1总结了具有不同交叉验证数据集的Se, Sp和Acc的结果, 本文提出的算法取得了很好的检测效果。最佳房颤检测参数为 $N=80$, 观察窗为32, 敏感性为98.71%, 特异度为98.43%, 总准确率为98.57%。由表中可以看到尽管字典原子总数 N 、观察窗口 n 和交叉验证数据集都有变化, Se, Sp和Acc总体变化不大。在实验中选择字典原子数 N 的原则是: 既要尽可能多以保证字典能够包含所有原子种类, 又要尽可能少以防止数据冗余带来不必要的计算量。表1中可以看到当原子总数为80或100时, 得到了交叉验证的最佳检测效果, 证明此时为

过完备字典的最佳结构。在交叉验证中, 相同的设置参数选用不同的子集进行原子训练得到的检测结果相差不大, 说明该方法具有很好的泛化能力。

近年来有关基于RR间期特征检测阵发性房颤文献的分类结果如表2所示, 所得分类结果都是基于MIT-BIH AFDB, 性能都用小数点后两位表示。与现有检测器相比本文设计的检测器在各个性能上均略有提高。表2中的大多数检测器^[8,18-20]采用窗口为128或者更长的RR间期数据窗口, 但这种长度窗口的检测器容易错过短暂的PAF发作。在综合评估检测器性能时, 出于前面提到的原因, 还是要

表 1 参数变化的检测性能(%)

字典原子数(N)	重复交叉验证	分割滑动窗口(n)								
		16			32			64		
		Se	Sp	Acc	Se	Sp	Acc	Se	Sp	Acc
40	数据集1	97.99	96.63	97.32	98.44	97.95	98.19	98.86	97.75	98.30
	数据集2	97.95	97.42	97.68	98.74	98.15	98.44	98.67	98.43	98.55
	数据集3	98.00	97.99	97.99	98.65	98.51	98.51	98.97	98.30	98.64
	数据集4	97.38	98.44	97.91	98.50	98.67	98.59	98.78	98.57	98.67
	数据集5	98.36	98.34	98.35	98.49	98.55	98.52	98.89	98.57	98.73
	平均	97.94	97.76	97.85	98.56	98.37	98.45	98.83	98.32	98.58
60	数据集1	98.15	96.91	97.53	98.38	98.31	98.34	98.97	96.04	97.51
	数据集2	98.26	97.32	97.79	98.06	98.12	98.09	98.46	94.26	96.36
	数据集3	98.32	97.10	97.71	98.19	98.52	98.36	98.97	98.40	98.68
	数据集4	97.76	98.41	98.09	98.78	98.52	98.65	98.91	98.64	98.78
	数据集5	98.03	98.67	98.35	98.57	98.60	98.58	98.86	98.53	98.69
	平均	98.10	97.68	97.89	98.39	98.41	98.40	98.83	97.17	98.00
80	数据集1	98.15	97.26	97.70	98.52	98.24	98.38	98.97	98.17	98.57
	数据集2	97.99	97.43	97.71	98.81	98.27	98.54	98.97	98.35	98.66
	数据集3	97.98	97.96	97.97	98.86	98.31	98.58	99.00	98.48	98.74
	数据集4	97.39	98.24	97.81	98.73	98.66	98.69	98.93	98.44	98.69
	数据集5	97.60	98.62	98.11	98.65	98.66	98.65	98.88	98.67	98.78
	平均	97.82	97.90	97.86	98.71	98.43	98.57	98.95	98.42	98.69
100	数据集1	98.29	97.29	97.79	98.77	98.23	98.50	99.00	97.01	98.01
	数据集2	98.13	97.72	97.92	98.81	98.09	98.45	98.94	98.56	98.75
	数据集3	97.70	97.72	97.71	97.52	98.51	98.01	98.94	98.80	98.87
	数据集4	97.90	98.38	98.14	98.60	98.72	98.66	98.94	98.80	98.87
	数据集5	98.35	98.47	98.41	98.70	98.68	98.69	98.97	98.63	98.80
	平均	98.07	97.92	97.95	98.48	98.45	98.46	98.96	98.36	98.66
120	数据集1	96.64	94.03	95.33	97.87	95.86	96.86	98.89	97.10	97.99
	数据集2	98.11	93.22	95.66	98.81	97.74	98.28	97.73	97.84	97.79
	数据集3	97.59	97.49	97.04	98.79	98.54	98.66	99.00	97.36	98.18
	数据集4	98.24	98.10	98.17	98.50	98.59	98.54	98.94	98.46	98.70
	数据集5	98.23	98.44	98.34	98.34	98.68	98.51	98.80	98.54	98.67
	平均	97.76	96.26	96.91	98.46	97.88	98.17	98.67	97.86	98.27

着重考虑检测短暂PAF发作的能力。Petrénas等人^[7]分别对窗口为15和60的数据验证了算法性能,为15拍时得到96.7%的敏感性和97.9%的特异度,为60拍时得到97.1%的敏感性和98.3%的特异度。文献^[10]也研究了较短窗口下的检测方法,窗口为31拍时敏感性为98.98%,特异度为96.95%,总准确率为97.80%。而本文方法使用短检测窗 $n=16$ 时,就达到了98.07%的敏感性和97.92%的特异度。当使用检测窗 $n=32$ 时,效果更优为敏感性98.71%、特异度98.43%、总准确率为98.57%,是现有检测算法中性能最好的。由此表明,本文所提算法在适用于较短窗口的绝对优势之外还具有更佳

表2 不同算法分类效果对比(%)

文献	年份	RR间期长度	Se	Sp	Acc
Lian等人 ^[20]	2011	128	95.89	95.40	-
Huang等人 ^[18]	2011	128	96.10	98.10	-
Petrénas等人 ^[7]	2015	60	97.10	98.30	-
Zhou等人 ^[19]	2015	128	97.37	98.44	97.99
Cui等人 ^[8]	2017	150	97.04	97.96	97.78
Andersen等人 ^[10]	2018	31	98.98	96.95	97.80
本文方法	2019	33	98.71	98.43	98.57

3.4 讨论

研究表明,当使用标准的治疗策略评估(即至少两次24 h Holter记录)介入治疗后PAF常常被忽略。因此,应该建议在更长的时间跨度内进行持续的PAF发作监测。然而,目前的大多数技术不允许连续监测,因为大多数PAF检测器需要大量的计算,这使得高效率的实现变得困难,特别是对于涉及心电图形态特征的检测器。而本文设计的检测器仅使用较短的RR间期数据,不使用其他心电图形态信息,大大降低了数据量与计算时间。直接利用稀疏向量与类别字典的重构残差即可实现分类,不需要计算多种复杂特征也无需利用分类器,避免了对参数的依赖。本文主要抓住了HRV信号在不规则变化中的空间结构特征,通过弯曲的黎曼流形空间的映射以更好的视角观测数据差异。进一步由基于核的稀疏编码方法利用字典的冗余特征捕捉其内在的本质结构与属性,得到的稀疏表示能够直观的反应数据类别。在选用最佳设置参数的情况下,检测结果的敏感性为98.71%,特异度为98.43%,总准确率为98.57%。由此表明,本文提出的核稀疏编码方法在相当长的时间内检测房颤发作是相当可靠的。

图3中按字典原子总数 N 和数据分割窗口 n 表示计算时间,每次计算的 Δ 值区间大约为0.000~

0.0175 ms。与数据分割窗口 n 相比,字典原子总数 N 对计算时间的影响更大。计算时间为0.032~0.037 ms ($N=40$), 0.221~0.251 ms ($N=120$)。最佳AF检测参数($N=80, n=32$),计算时间为0.107 ms。(程序用MATLAB R2015a编写,在Intel(R) Xeon(R) E5-2680 V3 CPU @2.50GHz (2处理器)处理器上运行,戴尔,中国保定)。这表明,在实际应用中,本文的算法是可以实时实现的,而且它比许多其他算法更快:文献^[8]当 $n=150$ 时计算时间为9.13 ms,文献^[20]当 $n=128$ 时计算时间为20~30 ms, $n=12$ 时计算时间为3~4 ms,文献^[19]当 $n=128$ 时计算时间为0.774 s,文献^[10]当 $n=31$ 时分析24 h ECG数据需要不到1 s的时间。本文既缩短了检测时间又提高了检出率,满足了移动监测设备对算法的要求。




图3 PAF参数变化的所需计算时间

4 结束语

本文提出了一种新的阵发性房颤检测方法,是对传统AF检测方法的补充。本文方法仅根据较短RR间期特征就能可靠地检测出PAF发作,数据量小且计算简单,适用于内存与计算能力有限的移动设备。主要内容为稀疏编码在Log-Euclid框架中利用核方法实现,其中RR间期序列由协方差描述子表示,采用迭代的方式在流行上学习过完备字典。对AFDB中不同训练集的实验结果表明本文提出的方法可以精准地检测PAF,与其他方法相比提高了检测性能。但是不同的患者表现出不同的AF和非AF模式,字典原子在不同受试者之间可能不一致。此外,同一患者在不同的活动中ECG也会出现不同的波动,例如在清醒期和睡眠期间。所以,如果使用更丰富的数据,可以建立更加完备的字典库,可能有助于算法性能进一步提高。

参考文献

- [1] HAQQANI H M, CHAN K H, GREGORY A T, *et al.* Atrial fibrillation: State of the art in 2017-shifting paradigms in pathogenesis, diagnosis, treatment and

- prevention[J]. *Heart, Lung and Circulation*, 2017, 26(9): 867–869. doi: [10.1016/s1443-9506\(17\)31276-3](https://doi.org/10.1016/s1443-9506(17)31276-3).
- [2] DE SISTI A, LECLERCQ J F, HALIMI F, *et al.* Evaluation of time course and predicting factors of progression of paroxysmal or persistent atrial fibrillation to permanent atrial fibrillation[J]. *Pacing and Clinical Electrophysiology*, 2014, 37(3): 345–355. doi: [10.1111/pace.12264](https://doi.org/10.1111/pace.12264).
- [3] ZHOU Xiaolin, DING Hongxia, UNG B, *et al.* Automatic online detection of atrial fibrillation based on symbolic dynamics and Shannon entropy[J]. *BioMedical Engineering OnLine*, 2014, 13(1): 18. doi: [10.1186/1475-925X-13-18](https://doi.org/10.1186/1475-925X-13-18).
- [4] SEPULVEDA-SUESCUN J P, MURILLO-ESCOBAR J, URDA-BENITEZ R D, *et al.* Atrial Fibrillation Detection Through Heart Rate Variability Using a Machine Learning Approach and Poincare Plot Features[M]. TORRES I, BUSTAMANTE J, and SIERRA D A. VII Latin American Congress on Biomedical Engineering CLAIB 2016, Bucaramanga, Santander, Colombia. Singapore: Springer Nature Singapore Pte Ltd, 2016: 565–568.
- [5] ANDERSEN R S, PEIMANKAR A, and PUTHUSSERYPADY S. A deep learning approach for real-time detection of atrial fibrillation[J]. *Expert Systems with Applications*, 2019, 115: 465–473. doi: [10.1016/j.eswa.2018.08.011](https://doi.org/10.1016/j.eswa.2018.08.011).
- [6] 季虎, 孙即祥, 王春光. 基于小波变换的自适应QRS-T对消P波检测算法[J]. *电子与信息学报*, 2007, 29(8): 1868–1871. doi: [10.3724/SP.J.1146.2006.00117](https://doi.org/10.3724/SP.J.1146.2006.00117).
JI Hu, SUN Jixiang, and WANG Chunguang. An adaptive QRS-T cancellation based on wavelet transform for P-wave detection[J]. *Journal of Electronics & Information Technology*, 2007, 29(8): 1868–1871. doi: [10.3724/SP.J.1146.2006.00117](https://doi.org/10.3724/SP.J.1146.2006.00117).
- [7] PETRĚNAS A, SÖRNMO L, LUKOŠEVIČIUS, *et al.* Detection of occult paroxysmal atrial fibrillation[J]. *Medical & Biological Engineering & Computing*, 2015, 53(4): 287–297. doi: [10.1007/s11517-014-1234-y](https://doi.org/10.1007/s11517-014-1234-y).
- [8] CUI Xingran, CHANG E, YANG Wenhua, *et al.* Automated detection of paroxysmal atrial fibrillation using an information-based similarity approach[J]. *Entropy*, 2017, 19(12): 677. doi: [10.3390/e19120677](https://doi.org/10.3390/e19120677).
- [9] XIN Yi and ZHAO Yizhang. Paroxysmal atrial fibrillation recognition based on multi-scale wavelet α -entropy[J]. *BioMedical Engineering OnLine*, 2017, 16(1): 121. doi: [10.1186/s12938-017-0406-z](https://doi.org/10.1186/s12938-017-0406-z).
- [10] TUZEL O, PORIKLI F, and MEER P. Region covariance: A fast descriptor for detection and classification[C]. Proceedings of the 9th European Conference on Computer Vision, Graz, Austria, 2006: 589–600.
- [11] ZHANG Yingying, YANG Cai, and ZHANG Ping. Two-stage sparse coding of region covariance via Log-Euclidean kernels to detect saliency[J]. *Neural Networks*, 2017, 89: 84–96. doi: [10.1016/j.neunet.2017.02.012](https://doi.org/10.1016/j.neunet.2017.02.012).
- [12] ARSIGNY V, FILLARD P, PENNEC X, *et al.* Geometric means in a novel vector space structure on symmetric positive-definite matrices[J]. *SIAM Journal on Matrix Analysis and Applications*, 2007, 29(1): 328–347. doi: [10.1137/050637996](https://doi.org/10.1137/050637996).
- [13] SCHÖLKOPF B and SMOLA A J. Learning with Kernels: Support Vector Machines, Regularization, Optimization, and Beyond[M]. Cambridge, USA: MIT Press, 2018: 13. doi: [10.7551/mitpress/4175.003.0018](https://doi.org/10.7551/mitpress/4175.003.0018).
- [14] LI Peihua, WANG Qilong, ZUO Wangmeng, *et al.* Log-Euclidean kernels for sparse representation and dictionary learning[C]. 2013 IEEE International Conference on Computer Vision. New York, USA, 2013: 1601–1608. doi: [10.1109/ICCV.2013.202](https://doi.org/10.1109/ICCV.2013.202).
- [15] GOLDBERGER A L, AMARAL L A N, 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. doi: [10.1161/01.CIR.101.23.e215](https://doi.org/10.1161/01.CIR.101.23.e215).
- [16] HARANDI M T, SANDERSON C, HARTLEY R, *et al.* Sparse coding and dictionary learning for symmetric positive definite matrices: A kernel approach[C]. The 12th European Conference on Computer Vision, Florence, Italy, 2012: 216–229. doi: [10.1007/978-3-642-33709-3_16](https://doi.org/10.1007/978-3-642-33709-3_16).
- [17] HUANG Chao, YE Shuming, CHEN Hang, *et al.* A novel method for detection of the transition between atrial fibrillation and sinus rhythm[J]. *IEEE Transactions on Biomedical Engineering*, 2011, 58(4): 1113–1119. doi: [10.1109/TBME.2010.2096506](https://doi.org/10.1109/TBME.2010.2096506).
- [18] ZHOU Xiaolin, DING Hongxia, WU Wanqing, *et al.* A real-time atrial fibrillation detection algorithm based on the instantaneous state of heart rate[J]. *PLoS One*, 2015, 10(9): e0136544. doi: [10.1371/journal.pone.0136544](https://doi.org/10.1371/journal.pone.0136544).
- [19] LIAN Jie, WANG Lian, and MUESSIG D. A simple method to detect atrial fibrillation using RR intervals[J]. *The American Journal of Cardiology*, 2011, 107(10): 1494–1497. doi: [10.1016/j.amjcard.2011.01.028](https://doi.org/10.1016/j.amjcard.2011.01.028).
- [20] LEE J, NAM Y, MCMANUS D D, *et al.* Time-varying coherence function for atrial fibrillation detection[J]. *IEEE Transactions on Biomedical Engineering*, 2013, 60(10): 2783–2793. doi: [10.1109/TBME.2013.2264721](https://doi.org/10.1109/TBME.2013.2264721).
- 刘明: 男, 1972年生, 博士, 副教授, 研究方向为模式识别和心电信号处理。
孟宪辉: 女, 1994年生, 硕士生, 研究方向为心电信号处理。
熊鹏: 女, 1986年生, 博士, 讲师, 研究方向为模式识别和生物信号处理。
刘秀玲: 女, 1977年生, 博士, 教授, 研究方向为生物医学成像和信号处理。