

基于深度学习和模糊 C 均值的心电 信号分类方法

吴志勇^{1,2} 丁香乾¹ 许晓伟¹ 鞠传香²

摘要 针对长时海量心电信号自动分类系统中, 心电专家诊断费时、费力 and 成本高, 心电信号形态复杂导致特征提取困难, 异常诊断模型适应性差、准确度低等问题, 本文提出一种基于深度学习和模糊 C 均值的心电信号分类方法. 该方法主要包括心电信号降噪预处理、心电信号分段和采样点统一化、无监督心跳特征学习、模糊 C 均值分类 4 个步骤, 给出了模糊 C 均值深度信念网络 FCMDNB 模型结构和学习分类算法. 仿真实验基于 MIT-BIH 心率异常数据库表明, 与基于传统心电特征人工设计的分类方法相比, 本文提出的信号诊断方法具有较高的适应性和准确度.

关键词 心电信号分类, 深度学习, 模糊 C 均值, 深度信念网络

引用格式 吴志勇, 丁香乾, 许晓伟, 鞠传香. 基于深度学习和模糊 C 均值的心电信号分类方法. 自动化学报, 2018, 44(10): 1913–1920

DOI 10.16383/j.aas.2018.c170417

A Method for ECG Classification Using Deep Learning and Fuzzy C-means

WU Zhi-Yong^{1,2} DING Xiang-Qian¹ XU Xiao-Wei¹
JU Chuan-Xiang²

Abstract In the classification system for longtime and massive ECG signals, ECG diagnosis is time-consuming, laborious and costly. It is difficult to extract signal features because of the complex ECG morphology. The diagnosis model has low adaptability and accuracy. To solve the above problem, a novel method for ECG classification using deep learning and fuzzy C-means is proposed. The method includes four steps: ECG signal preprocessing, heartbeat segmentation and sampling point unification, ECG feature deep learning, fuzzy C-means classification. The structure and algorithm of fuzzy C-means deep belief networks (FCMDNB) are shown in the paper. The method is validated on the well-known MIT-BIH arrhythmia database. Experiment results show that the approach achieves higher adaptability and accuracy than traditional hand-designed methods on classification of ECG signals.

Key words ECG classification, deep learning, fuzzy C-means, deep belief networks (DBNs)

Citation Wu Zhi-Yong, Ding Xiang-Qian, Xu Xiao-Wei, Ju Chuan-Xiang. A method for ECG classification using deep learning and fuzzy C-means. *Acta Automatica Sinica*, 2018, 44(10): 1913–1920

据世界卫生组织统计, 2012 年全球约有 17.5 万人死于心血管疾病, 占全球死亡人数的 31 %^[1]. 为降低心脏疾病

的发生, 预防性的前期诊断是关键. 心电图作为一种重要的非侵入式心电检测工具被心脏专家广泛使用. 通常情况下, 针对短时心电图可通过视觉观察来识别各种心电信号异常的各种症状. 但是, 随着便携式心电图 (例如, Holter、Loop recorder) 的广泛使用, 因其可连续记录 24 小时、48 小时, 甚至 14 个月的心电信号记录^[2]. 面对庞大的数据, 采用传统的视觉方法判断心脏疾病已不可能, 取而代之的是采用智能化的心电信号自动分类技术.

心电信号自动分类系统通常包括 5 个阶段, 包括心电信号采集、预处理、心跳分段、特征提取和降维、自动分类, 如图 1 所示. 心电信号采集可综合利用智能硬件、物联网等核心技术远程采集心电信号数据, 汇入医疗健康数据仓库. 心电信号预处理主要去除心电信号的各种噪声, 为后续阶段处理提供干净的信号信息, 去除的心电噪声主要包括基线漂移、工频干扰和高频噪声等^[3]. 心跳分段的目的是提取每个完整的心跳周期波形, 需要检测 P 波、QRS 波群和 T 波等关键点^[4]. 针对心电信号预处理和心跳分段技术, 已有众多学者在文献中进行了研究并得到了广泛应用, 本文重点研究心电信号特征提取和自动分类两方面技术. 在心电信号特征提取方面, 近十年来大量文献提出了各种方法, 包括心电信号形态特征^[3]、时间间隔特征^[5]、小波变换特征^[6]和高阶统计特征^[7]等. 为获取更有效的特征集合, 在分类系统应用中往往组合运用多种类型的心电信号特征, 为此, 特征降维方法, 例如主成分分析、独立成分分析等^[6–9]常应用于上百心电特征的关键特征提取中. 在心电信号自动分类技术方面, 以低维特征空间为基础, 分类模型多采用各种智能算法, 例如人工神经网络^[9]、最近路径森林^[10]、群智能算法^[11]和模糊分类^[12]等.

从以上提到的各种文献来看, 尽管各种心电信号分类系统在特定心电信号数据集 (例如, MIT-BIH、AHA 和 CSE 数据库等) 取得较高的准确率. 但仍然面临以下几个问题: 1) 特征提取的过程通常需要心脏专家的参与, 导致时间和费用成本的增加; 2) 因心电特征需人工设计, 可能造成源心电信号特征信息丢失; 3) 构建的心电信号分类模型对不同病患者具有低适应性的缺陷. 针对上述问题, 近年来, 随着深度无监督特征提取技术的深入研究, 基于深度学习技术的心电信号自动分类系统得到广泛关注.

深度学习思想是对输入层数据可自动学习特征的过程. 与传统方法相比, 深度学习已在图像识别^[13]、语音识别^[14]和生理数据分析^[15]等方面取得较好的成绩. 典型的深度学习框架包括深度信念网络 (Deep belief network, DBN)^[16]、栈式自编码器 (Stacked auto-encoder, SAE)^[17]和卷积神经网络 (Convolutional neural network, CNN)^[18]等. 基于深度学习方法进行心电信号自动识别已有众多学者开展研究, 并取得了较好的结果. 例如, Kiranyaz 等^[19]采用一维卷积神经网络提取信号特征为特定病人进行心电异常实时诊断; Rahhal 等^[15]提出采用栈式自动编码器从源心电信号中学习特征进行心电信号分类, 并用 Softmax 算法实现多心律分类; Yan 等^[20]和 Meng 等^[21]均基于受限玻尔兹曼机 (Restricted Boltzmann machine, RBM) 构造的 DBN 提取心电特征, 在分类技术方面, 前者使用 Softmax 多分类器, 后者使用支持向量机决策树. 从上述文献来看, 基于无监督深度学习的心电特征提取技术相对于传统的人工特征设计方法优势突出, 而在心电信号分类技术方面, 仍旧难以体现心电信号模糊分类特性. 传统心电信号异常诊断中, 医生的诊

收稿日期 2017-07-26 录用日期 2017-12-06
Manuscript received July 26, 2017; accepted December 6, 2017
国家重点研发计划 (2016YFB1001103) 资助
Supported by National Key Research and Development Program of China (2016YFB1001103)
本文责任编辑 付俊
Recommended by Associate Editor FU Jun
1. 中国海洋大学信息科学与工程学院 青岛 266100 2. 山东理工大学计算机科学与技术学院 淄博 255000
1. College of Information Science and Engineering, Ocean University of China, Qingdao 266100 2. School of Computer Science and Technology, Shandong University of Technology, Zibo 255000

断过程本身具有模糊性,而且大量复杂多样心电信号中异常心跳属于少数.因此,采用具有对稀有数据敏感特性、模糊性和更符合人类思维过程的模糊聚类过程算法进行心电信号分类得到广泛研究.Özbay 等^[22]结合模糊 C 均值 (Fuzzy c-means, FCM) 聚类算法和多层感知机对多种心电信号分类; Yeh 等^[23]利用 FCM 算法对异常心电分类并给出了 4 个详细的聚类步骤.本文综合深度学习与模糊分类技术的优势,提出一种结合深度学习和模糊 C 均值技术的心电信号分类方法.首先,描述了该方法的技术流程,包括心电信号降噪预处理、心电信号分段和采样点统一化、无监督心跳特征学习、模糊分类等;然后,提出模糊 C 均值深度信念网络模型结构和算法,介绍了面向心电信号特征提取的深度网络 DBN 构建方法和面向心电信号的模糊 C 均值分类方法;最后,基于 MIT-BIH 心律异常数据库进行仿真实验,验证该方法的有效性.

1 提出的方法

本文基于深度学习和模糊 C 均值的心电信号分类技术流程如图 2 所示,心电信号降噪预处理、心电信号分段和采样点统一化、无监督心跳特征学习、模糊分类 4 个步骤依次推进、相互依赖,每个步骤都影响着最终分类结果的准确性.

1.1 心电信号降噪预处理

采集的心电信号通常需要去除基线漂移、肌电噪声和工频噪声等干扰信号,提高波形检测和分类准确率.从去噪预处理技术发展来看,主要包括数字滤波器技术、自适应滤波器技术和以小波变换、数学形态学及神经网络为代表的现代高新滤波技术.由于数字滤波器具有很好的系统可靠性、低廉的设计成本及灵活方便的应用性等优点,是心电信号预处

理最简单且广泛的应用技术.本文按照 de Chazal 等^[3]提出的降噪预处理方法,先用 200 ms 中值滤波去除 QRS 波群和 P 波,然后再用 600 ms 的中值滤波去除 T 波,最后用源信号减去两个中值滤波后的信号即可得到去除基线漂移心电信号,肌电和工频噪声信号使用带有 35 Hz、3 dB、12-tap 低通滤波器去除,最后得到可用于后续处理的心电信号.

1.2 心电信号分段与采样点统一化

心电信号分技术已有三十多年的研究历史,主要围绕 P 波峰和 QRS 波群的检测来展开. Pan 等^[4]提出了一种基于数字滤波的检测方法,可有效检测 P、QRS 和 T 波的波峰、上下沿等关键点,该方法因其简单性和有效性得到广泛应用.本文利用基于该方法开发的 Ecgpwave 工具 “<http://www.physionet.org/physiotools/wag/ecgpw-1.htm>” 识别心电信号各种波形边界,以实现心电信号心跳分段.根据检测获取的各个关键点计算后,可容易分段各心跳样本.因不同的个人身体状况具有不同的心跳周期,分段后的样本具有不同的采样点数目,而心电特征抽取模型需要统一的输入.为此,需要对心跳样本进行采样点统一化处理,本文采用插值算法对获取到的心跳样本统一化为 200 个采样点.

1.3 无监督心跳特征学习

无监督特征学习可自动抽取无标签样本特征,相对人工设计特征的方式能够更好地发现潜在特征,且减少数据专家参与,具有省时、省力,降低数据分析成本的优点.目前,具有无监督特征学习能力的模型结构有多种,例如受限玻尔兹曼机 (RBM)^[16] 及其扩展模型条件 RBM^[24]、门限 RBM^[25]、自动编码器 (Auto-encoder, AE)^[26]、循环神

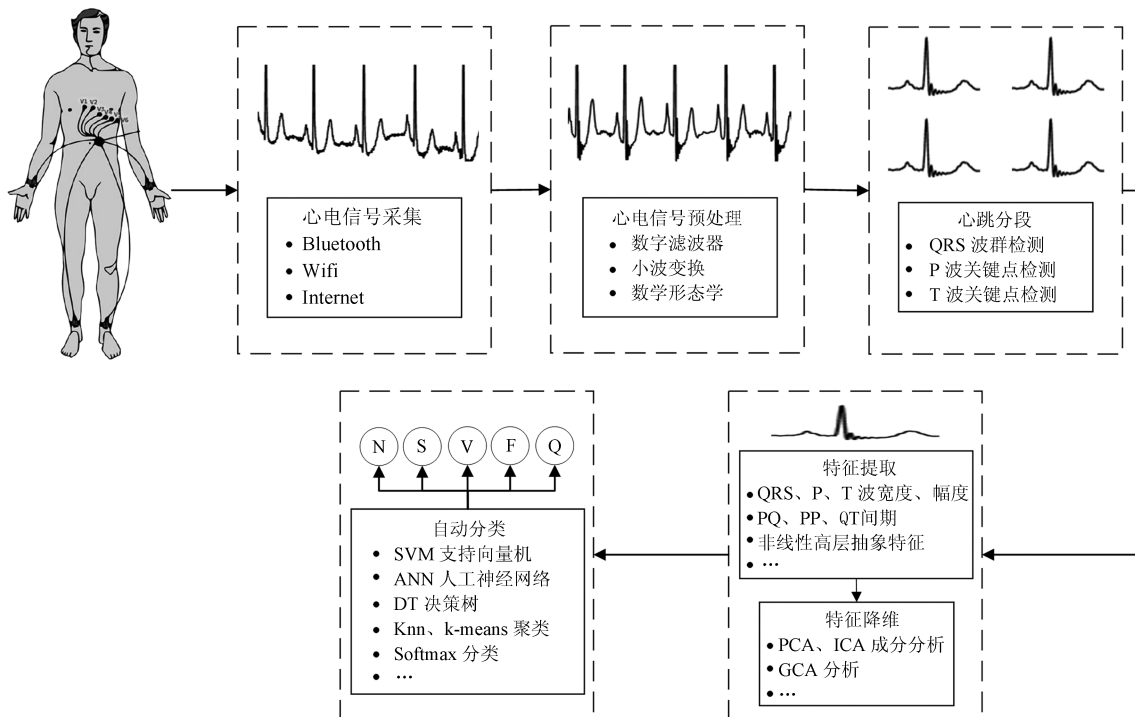


图 1 心电信号自动分类系统流程

Fig. 1 The system flow of ECG classification

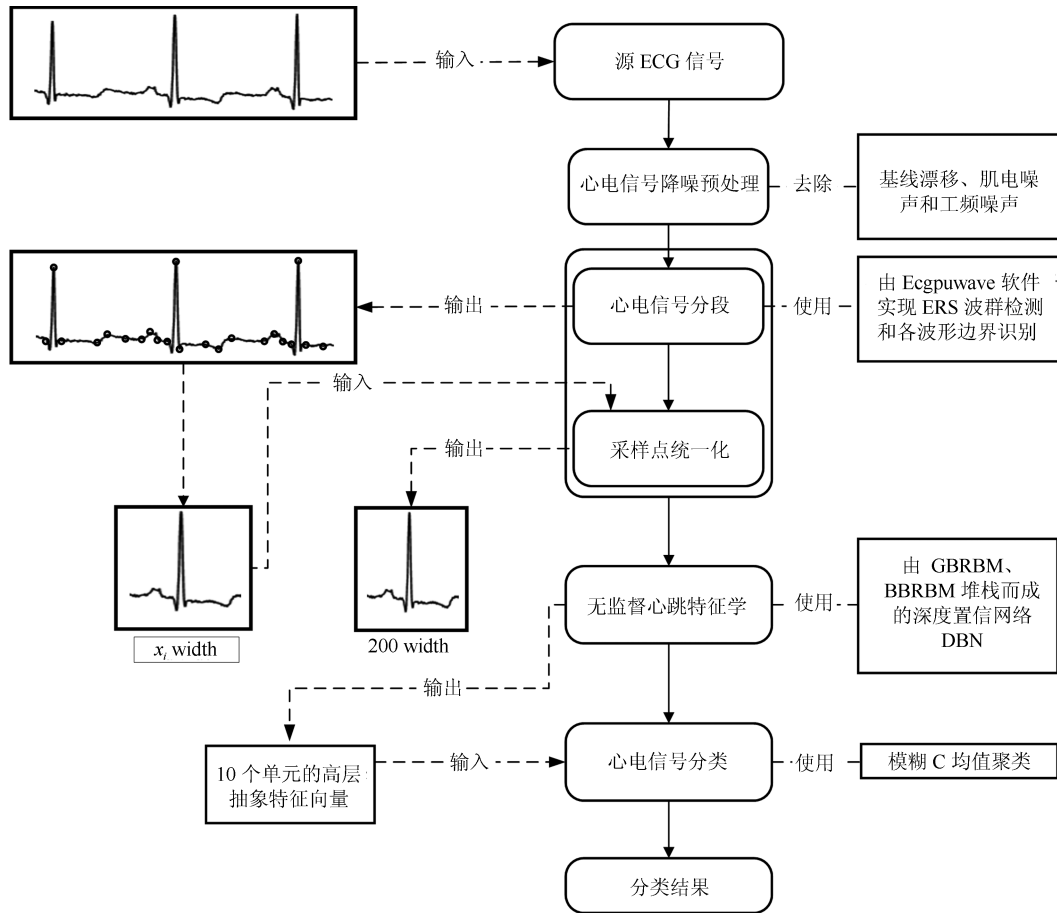


图 2 基于深度学习和模糊 C 均值的心电信号分类技术流程

Fig. 2 The process of ECG classification using deep learning and fuzzy C-means

神经网络 (Recurrent neural network, RNN)^[27] 等。本文采用具有无监督特征学习能力的 DBN 抽取心电信号的高层抽象特征, 该 DBN 由多层高斯伯努利 RBM (Gaussian-Bernoulli RBM, GBRBM) 和伯努利伯努利 RBM (Bernoulli-Bernoulli RBM, BBRBM) 堆栈而成, 最底层 GBRBM 用于接收连续值心电信号, 最顶层使用线性激活函数输出连续特征向量, 构建过程包括无监督模型训练和有监督模型优化微调两个阶段。

1.4 心电信号模糊分类

近年来, 模糊系统在医疗健康领域得到广泛应用, 用于诊断和识别各种疾病, 例如帕金森疾病^[28]、乳腺癌^[29]和肝脏疾病^[30]等。从文献来看, 无监督模糊分类技术不仅应用于医疗图像分段分析, 还广泛用于各种医疗体征信号的识别诊断中。例如, Meau 等^[31]基于多层感知机扩展了卡尔曼滤波, 构建了一套复杂的模糊系统用于心电信号分类。Ozbay 等^[32]利用模糊聚类神经网络进行早期心脏疾病诊断。本文以深度模型抽取的心电信号高层抽象特征为数据基础, 采用目前最为广泛使用的 FCM 算法进行心电信号分类。FCM 算法最早在 1973 年由 Dunn 提出^[33], 1981 年 Bezdek 对该算法进行了优化^[34], 被广泛应用于图像检索、语音识别和模式识别等领域。

2 模糊 C 均值深度信念网络模型

分段采样点统一化后的心电信号数据集可表示为 $s = [s^1, s^2, \dots, s^{R+T}]$, 其中, $s = [s_1, s_2, \dots, s_D]^T$ 表示每条心电信号采样数据, R 是训练样本数, T 是测试样本数, D 是每条心电信号的采样点数。从 R 条训练样本中随机或主动挑选 L 条构成训练样本 $X^L = [x^1, \dots, x^L]$, 其中 $1 \leq L \leq R$ 。则对应的样本标签向量为 $Y^L = [y^1, y^2, \dots, y^L]$, 其中 $y = [y_1, y_2, \dots, y_c]^T$, c 表示标签类数量, 其中 y_i 取值如式 (1) 所示。

$$y_i = \begin{cases} 1, & x \text{ 属于 } i \text{ 类} \\ 0, & x \text{ 不属于 } i \text{ 类} \end{cases} \quad (1)$$

则网络模型的实现目标是基于采集的心电信号数据找到 $X^L \rightarrow Y^L$ 的映射关系。本文提出的模糊 C 均值深度网络结构包括 DBN 抽象特征提取和 FCM 分类两部分, 如图 3 所示。底层 DBN 网络模型由多层无方向的受限玻尔兹曼机 (RBM) 堆建而成, 含有一层可接收连续心电信号的可见单元和多层二值隐藏单元, 最后输出高层连续抽象特征向量, 为构建 DBN 模型通常需要无监督学习训练和模型微调两个阶段。顶层 FCM 分类模型以 DBN 输出的高层抽象特征为基础, 计算每类心电信号的聚类中心, 然后计算最短距离的方式进行心电信号的模糊分类, 为构建 FCM 模型一般需要计算心电信号聚类中心和中心距离计算两个阶段。

2.1 深度网络 DBN 构建

心电信号 DBN 模型采用经典的由低到高逐层贪婪无监督训练 RBM 方法, 对深度网络内的 RBM 参数进行设置. RBM 作为 DBN 的基本模块具有很强的非线性无监督学习能力, 能够从复杂的数据中学习有用信息, 具备针对一组状态 (v, h) 的能量定义. 模型第一层 RBM 因需要接收心电信号连续值, 则使用高斯-伯努利 RBM (GBRBM), 其能量定义如式 (2). 模型其他层 RBM 均为伯努利-伯努利 RBM (BBRBM), 其能量定义如式 (3).

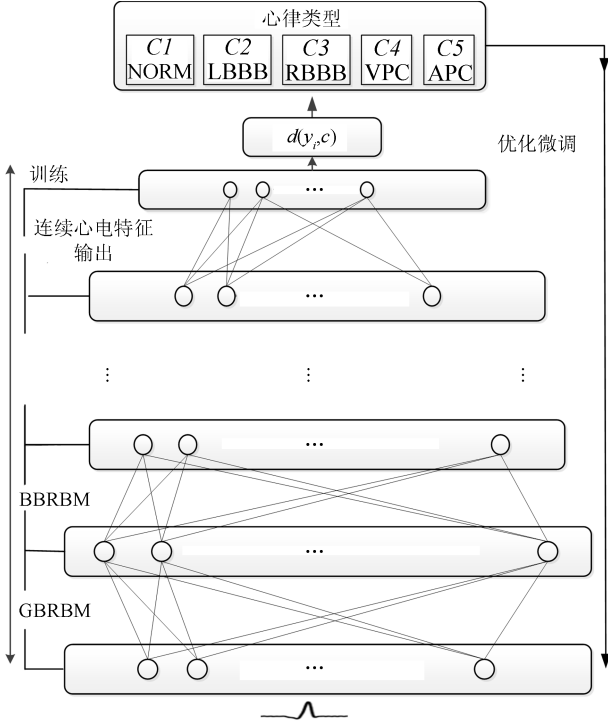


图 3 模糊 C 均值深度网络结构

Fig. 3 Fuzzy C-means deep network structure

$$E(v, h; \theta_1) = \sum_{i=1}^n \frac{(v_i - a_i)^2}{2\sigma_i^2} - \sum_{j=1}^m b_j h_j - \sum_{i=1}^n \sum_{j=1}^m \frac{v_i}{\sigma_i} h_j w_{ij} \quad (2)$$

$$E(v, h; \theta_2) = \sum_{i=1}^n \frac{(v_i - a_i)^2}{2\sigma_i^2} - \sum_{j=1}^m b_j h_j - \sum_{i=1}^n \sum_{j=1}^m \frac{v_i}{\sigma_i} h_j w_{ij} \quad (3)$$

其中, v 表示 RBM 的可见层单元向量, h 表示 RBM 的隐藏层单元向量. $\theta_1 = \{w, a, b, \sigma\}$, $\theta_2 = \{w, a, b\}$ 分别为 GBRBM 和 BBRBM 的参数向量, W 表示 RBM 可见层单元和隐藏层单元之间的无向权值向量, a 和 b 分别为可见层单元和隐藏层单元的偏置向量, σ 为可见层单元高斯噪声的标准差向量. n 表示可见层单元数量, m 表示隐藏层单元数量.

因 RBM 具有层间连接、层内无连接的结构, 可方便计算第 j 个隐藏单元的条件概率和第 i 个可见单元的条件概

率. 则针对 GBRBM 和 BBRBM, 条件概率计算公式分别为式 (4)、(5) 和式 (6)、(7).

$$p(v_i = v | h, \theta_1) = \eta \left(v | a_i + \sum_{j=1}^n h_j w_{ij}, \sigma_i^2 \right) \quad (4)$$

$$p(h_j = 1 | v, \theta_1) = \delta \left(b_j + \sum_{i=1}^n \frac{v_i}{\sigma_i^2} w_{ij} \right) \quad (5)$$

$$p(v_i = 1 | h, \theta_2) = \delta \left(a_i + \sum_{j=1}^m h_j w_{ij} \right) \quad (6)$$

$$p(h_j = 1 | v, \theta_2) = \delta \left(b_j + \sum_{i=1}^n v_i w_{ij} \right) \quad (7)$$

其中, $\eta(\cdot | u, \sigma^2)$ 表示均值 u 和方差 σ^2 的高斯概率密度函数, $\delta(x)$ 表示逻辑回归函数.

利用心电信号数据训练 RBM 目的是获取 θ_1 和 θ_2 参数值, 可根据 Hinton 提出的对比散度快速学习算法^[35] 使其对数似然函数在训练集上最大化, 则连接权重 w_{ij} 、可见层单元的偏置 a_i 和隐藏层单元的偏置 b_j 的更新准则为:

$$\begin{aligned} \Delta w_{ij} &\approx \varepsilon \left(\left\langle \frac{v_i}{\sigma_i^2} h_j \right\rangle_{data} - \left\langle \frac{v_i}{\sigma_i^2} h_j \right\rangle_{model} \right) \\ \Delta a_i &\approx \varepsilon \left(\left\langle \frac{v_i}{\sigma_i^2} \right\rangle_{data} - \left\langle \frac{v_i}{\sigma_i^2} \right\rangle_{model} \right) \\ \Delta b_j &\approx \varepsilon \left(\langle h_j \rangle_{data} - \langle h_j \rangle_{model} \right) \end{aligned} \quad (8)$$

$$\begin{aligned} \Delta w_{ij} &\approx \varepsilon \left(\langle v_i h_j \rangle_{data} - \langle v_i h_j \rangle_{model} \right) \\ \Delta a_i &\approx \varepsilon \left(\langle v_i \rangle_{data} - \langle v_i \rangle_{model} \right) \\ \Delta b_j &\approx \varepsilon \left(\langle h_j \rangle_{data} - \langle h_j \rangle_{model} \right) \end{aligned} \quad (9)$$

依据 DBN 深度框架从低到高逐层训练 RBM 的方法, 在初始阶段各层之间的连接权重 w 和偏置 a, b 全部随机产生, 最顶层输出 h^t 即为心电信号的高层抽象特征, 如式 (10) 所示.

$$h^t = \delta(b^t + \sum h^{t-1} w^t) \quad (10)$$

DBN 无监督训练结束后, 使用 L 条有标签的心电信号样本通过梯度下降和反馈传播算法对参数进行优化微调以增强模型的性能, 此优化问题可用式 (11) 表达:

$$\theta^* = \arg \min \sum_{i=1}^L \sum_{j=1}^C \exp(-\delta^i (b_j^t + \sum h_j^{t-1} w_j^t) y_j^i) \quad (10)$$

2.2 模糊 C 均值分类

设 $H = \{h_1, h_2, \dots, h_L\}$ 是通过深度 DBN 模型抽取的对应 L 条心电信号样本的抽象特征向量, 若抽象特征维度为 p , 则 H 可用式 (12) 表示.

$$H = \begin{bmatrix} h_{1,1} & h_{1,2} & \cdots & h_{1,p} \\ h_{2,1} & h_{2,2} & \cdots & h_{2,p} \\ \vdots & \vdots & \ddots & \vdots \\ h_{L,1} & h_{L,2} & \cdots & h_{L,p} \end{bmatrix} \quad (12)$$

本文利用 FCM 算法, 通过最小化目标函数 (13), 不断更新隶属度和心电信号分类中心, 直到分类中心位置固定或两

次迭代的目标函数值之差在允许的范围内.

$$J(H; U, V) = \sum_{c=1}^C \sum_{l=1}^L (u_{c,l})^m (d_{c,l})^2 \quad (13)$$

其中, m 为模糊度参数, $U = (u_{c,l})_{C \times L}$ 为划分矩阵, 如式 (14), $u_{c,l}$ 为属于类 c 的 h_l 特征向量的隶属度, 且满足式 (15) 的两个条件, $V = \{v_1, v_2, \dots, v_C\}$ 为心电聚类中心向量集合, v_c 可根据式 (16) 计算, $d_{c,l}$ 为 h_l 样本特征向量到心电类 c 中心 v_c 的欧氏距离.

$$U = (u_{c,l})_{C \times L} = \begin{bmatrix} u_{1,1} & u_{1,2} & \cdots & u_{1,L} \\ u_{2,1} & u_{2,2} & \cdots & u_{2,L} \\ \vdots & \vdots & \ddots & \vdots \\ u_{C,1} & u_{C,2} & \cdots & u_{C,L} \end{bmatrix} \quad (14)$$

$$\begin{cases} 0 \leq u_{c,l} \leq 1, & 1 \leq c \leq C, 1 \leq l \leq L \\ \sum_{c=1}^C u_{c,l} = 1, & 1 \leq l \leq L \end{cases} \quad (15)$$

$$v_c = \frac{\sum_{l=1}^L (u_{c,l})^m h_l}{\sum_{l=1}^L (u_{c,l})^m}, \quad 1 \leq c \leq C \quad (16)$$

2.3 模糊 C 均值深度信念网络算法 FCMDDBN

传统的模糊神经网络通过调整模糊参数 m 来优化隶属度函数以达到对目标数据进行分类的目的. 而在模糊深度神经网络结构中, 针对心电信号分类需求, 模型的优化需要心电信号采样数据 L 、高层抽象心电特征向量 H 、模糊参数 m 和相应的标签向量 Y 协同建模与微调.

算法 1 描述了 FCMDDBN 的训练和分类过程, 因采样得到的心电信号是连续值数据, 在初始化 DBN 阶段需设置最底层 RBM 类型为 GBRBM, 其他层 RBM 类型为 BBRBM; 隐藏层单元个数、模型层数、训练次数和批次大小等参数根据心电信号数据维度和样本集大小确定; 动量学习率、学习率、惩罚率和初始偏置等, 则需要经验赋初始值; RBM 初始化权值向量则随机产生; 模糊分类个数和聚类终止阈值根据具体心电信号分类需求进行设置, 模糊度参数同样需经验赋值.

FCMDDBN 模型经过以下两个构建过程后可对心电信号类型进行分类:

1) 利用无标签和有标签的心电信号采样数据训练 DBN 模型, 获取心电信号类型的 FCM 划分矩阵. 首先, 利用无标签采用数据对 DBN 模型进行逐层贪婪无监督学习和有标签采样数据对 DBN 模型进行梯度下降监督学习. 然后, 依据获取的高层抽象心电信号特征向量数据计算每类心电信号的聚类中心, 构建划分矩阵.

2) 优化微调 FCMDDBN 模型. 结合反向回馈算法和 FCMDDBN 模糊分类功能, 利用有标签的心电信号采样数据进行逐层贪婪学习和梯度下降学习后对 FCMDDBN 模型参数进行调整优化.

算法 1. ECG-FCMDDBN

输入. 训练样本 $ds_training = \{(x_t, y_t)\}_{t=1}^L$; 测试样本 $ds_testing = \{(x_t, y_t)\}_{t=1}^T$

FCMDDBN 参数:

每层 RBM 类型 {GBRBM, BBRBM};
模型层数 n ; 每层单元个数 N_1, N_2, \dots, N_n ;
训练次数 E ; 随机初始化权值向量 w ; 初始化偏置向量 a, b ;

动量学习率 ϑ ; 学习率 η ; 惩罚率 p ; 批次大小 s ;
模糊分类个数 C ; 模糊度参数 m ; 聚类终止阈值 ε ;
输出. FCMDDBN 模型的权值向量 w , 偏置向量 a, b , 划分矩阵 U

步骤 1. 基于心电信号 $ds_training$ 训练样本对 DBN 进行逐层贪婪无监督学习

for $k = 1; k < n$ do

if $k == 1$ do

设置 RBM 可见单元 Gaussian 类型;

else if $k == n - 1$ do

设置 RBM 隐藏单元为 Gaussian 类型;

else do

设置 RBM 隐藏单元 Binary 类型;

end

for $e = 1; e \leq E$ do

for $l = 1; l \leq L$ do

if $k == 1$ do

根据式 (3) 和 (4) 分别计算 GBRBM 隐藏单元和可见单元的条件概率;

根据式 (7) 计算更新 GBRBM 连接权重和隐藏单元和可见单元偏置;

else do

if $k == n - 1$ do

设置激活函数为线性函数

else do

设置激活函数为逻辑回归函数

end

根据式 (5) 和 (6) 分别计算 BBRBM 隐藏单元和可见单元的条件概率;

根据式 (8) 计算更新 BBRBM 连接权重和隐藏单元和可见单元偏置;

end

end

end

end

步骤 2. 根据式 (10) 对训练的 DBN 进行有监督学习, 获取训练样本的高层抽象特征向量.

步骤 3. 根据式 (12) 计算每一种心电信号类型的聚类中心向量, 构建划分矩阵 U .

步骤 4. 采用 X^L, Y^L, U 微调 FCMDDBN 模型

再次基于心电信号 $ds_training$ 训练样本对 DBN 进行逐层贪婪无监督学习.

再次根据式 (10) 对训练的 DBN 进行有监督学习, 采用反向回馈算法调整 DBN 参数.

步骤 5. 基于心电信号 $ds_testing$ 测试样本进行分类.

3 实验与结果分析

3.1 实验数据

实验数据来源于 MIT-BIH 心律异常数据库, 该数据库由麻省理工学院开发, 数据全部采集于 Beth Israel 医院的心




图 4 5 类心律波形图

Fig.4 Five types of cardiac rhythms graph

表 1 5 类心律 MIT-BIH 实验数据集

Table 1 The data set of MIT-BIH including five types of cardiac rhythms

数据集	类型	心跳记录	NORM	LBBB	RBBB	PVC	APC	合计
DS1	训练数据集	100, 105, 108, 111, 114, 116, 118, 201, 203, 207, 208, 209, 215 219, 222, 228, 233	30 179	3 578	2 251	3 387	892	40 287
DS2	测试数据集	103, 106, 109, 119, 124, 205, 214, 221, 223, 231, 232	14 560	1 999	3 182	2 247	1 462	23 450

律异常实验室. MIT-BIH 心律异常数据库中每条记录采集心电信号时间约 30 分钟, 采样频率 360Hz, 心跳类型 18 种并已做标签注释. 共包含 48 条记录, 23 条心电记录可作为常规临床记录的代表性样本, 其他 25 条记录包含了复杂心室、交界和室上性等心律失常问题. 参照文献 [3] 中对心电信号预处理方式, 实验选取 5 类心律类型进行分类, 包括正常心跳 (NORM)、左束支传导阻滞 (LBBB)、右束支传导阻滞 (RBBB)、室性早搏 (PVC) 和房性早搏 (APC), 如图 4 中 (1-1)、(2-1)、(3-1)、(4-1) 和 (5-1) 所示. 不同人体对象通常具有不同的心跳频率, 分段后的心电信号具有不同的心跳长度, 实验对分段信号进行重插值抽样, 在保持原有波形形态的情况下得到统一长度为 200 个采样点的心跳信号, 如图 4 中 (1-2)、(2-2)、(3-2)、(4-2) 和 (5-2) 所示. 最后得到的 5 类心律实验数据集如表 1 所示, 其中 DS1 为训练数据集, DS2 为测试数据集.

3.2 实验与结果分析

实验中 FCMDNB 模型的 DBN 各层单元个数结构为 {200 - 400 - 300 - 100 - 50 - 10}, 第 1 层 200 单元接收统一宽度的心电信号连续数据, 第 6 层 10 单元输出心电信号的高层抽象特征信息. 模型定义动力学习率 = [0.4 0.3 0.2 0.1 0], 批次大小 = 100, 训练次数 = 50, 惩罚率 = 0.0002; FCM 模糊分类个数 = 5, 模糊度参数 $m = 1.2$, 聚类终止阈值 = 0.001. 实验利用台式计算机进行仿真, 设备配置为 Intel Core i7-4790, CPU 3.6GHz, RAM 16GB, and GPU Intel HD graphics 4600.

基于 DBN 抽取的样本 10 个心电特征数据, 本文对每类心律类型进行分析和聚类中心点计算. 箱线图 5 描述了每类心律特征值信息, 从图 5 结果来看, NORM、LBBB、RBBB、PVC 和 APC 5 类心律值具有明显可区分的分布范围. 表 2 给出了 5 类心律特征中心点数据, 基于中心点数据计算某心电信号的距离进行心律分类.

实验随机选择特征点向量为 [3.8624, 1.9699, -4.6216, 3.3794, 1.1686, 2.2271, 3.1660, 3.5609, -3.5019, 0.7997]

的样本, 其与各特征中心点的欧氏距离分别为 $d_1 = 14.4160, d_2 = 12.6650, d_3 = 9.6987, d_4 = 9.5196, d_5 = 10.6587$, 如图 6 所示, 根据距离最小原则, 该心电信号样本属于 RBBB 类型.

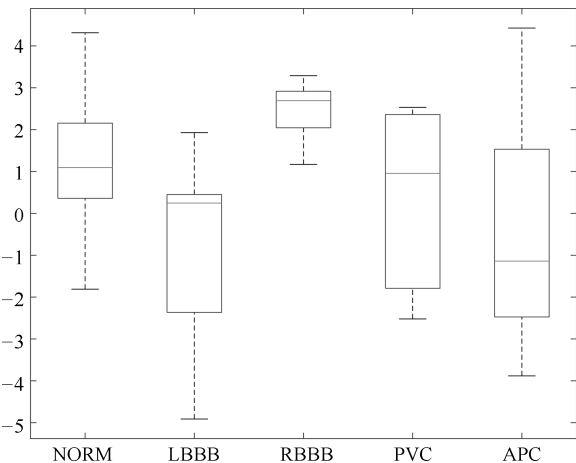


图 5 心律特征值分布范围

Fig.5 Distribution range of cardiac rhythms features value

为方便分类结果比较, 本文采用灵敏度 (Sensitivity, Se), 阳性预测值 (Positive predictive value, PPV) 和总准确率 (Total classification accuracy, TCA) 三种度量方式, 公式定义分别如下所示.

$$Se = \frac{TP}{TP + FN} \quad (17)$$

$$PPV = \frac{TP}{FP + TP} \quad (18)$$

$$TCA = \frac{TP + TN}{TP + FP + FN + TN} \quad (19)$$

其中, TP 表示心跳被正确分类的个数; FN 表示心跳被错误分类的个数; TN 表示不属于某种心跳被分类的个数; FP 表示属于某种心跳被错误分类的个数.

表 2 5 类心律特征中心点
Table 2 The centers of feature vectors of five kinds of cardiac rhythms

特征点	NORM	LBBB	RBBB	PVC	APC
F1	-1.8883	-4.9128	-1.8114	3.2888	2.3609
F2	-1.8629	0.2611	4.3143	2.0445	2.5327
F3	-2.4740	-2.5394	-1.5449	2.5297	2.2344
F4	-3.8821	0.3071	0.3587	2.9173	1.6611
F5	-2.4890	-0.4371	1.7242	1.1693	-2.5217
F6	-0.1716	-2.3649	1.0338	2.7506	2.4165
F7	-0.4175	1.6318	1.1534	3.2230	-2.3545
F8	1.5320	0.2320	3.5207	2.8277	0.2495
F9	4.4273	1.9278	2.1546	2.6333	-1.7905
F10	2.7375	0.4500	0.7206	1.4910	-0.8220




图 6 随机样本与各类心率中心点欧氏距离
Fig. 6 Euclidean distance between random sample and the center point of heart rate

表 3 是基于 FCMDBN 模型在 DS2 数据集上的分类混淆矩阵结果, 从表 4 分类结果性能比较来看, 本文采用的基于深度学习的模糊分类方法可自动提取源心电信号的全面高层抽象特征进行聚类, 相对其他方法具有较高的分类准确性, NORM、LBBB、RBBB、PVC、APC 5 类心律的分类性能分别为: $Se = 98.32\%$ $PPV = 99.28\%$; $Se = 98.32\%$, $PPV = 99.28\%$; $Se = 98.32\%$, $PPV = 99.28\%$; $Se = 98.32\%$, $PPV = 99.28\%$; $Se = 98.32\%$, $PPV = 99.28\%$, 总体准确率 $TCA = 96.54\%$ 。另外, 仿真实验中模型训练和测试采用了不同的数据集, 证明了所提方法对心电信号诊断的适应性更强。

表 3 FCMDBN 模型在 DS2 数据集上的分类混淆矩阵
Table 3 Confusion matrix for ECG arrhythmias classification on DS2 using the FCMDBN

心律类型	NORM	LBBB	RBBB	PVC	APC	Total
NORM	14 316	111	69	39	25	14 560
LBBB	23	1 811	57	51	57	1 999
RBBB	32	12	3 001	86	51	3 182
PVC	36	29	49	2 121	12	2 247
APC	12	20	11	28	1 391	1 462

表 4 分类结果性能比较

Table 4 Performance comparison of classification results

方法		NORM	LBBB	RBBB	PVC	APC
FCMDBN	Se (%)	98.32	90.59	94.31	94.39	95.14
	PPV (%)	99.28	91.32	94.16	91.22	90.55
	TCA (%)					96.54
FCMM ^[12]	Se (%)	98.28	90.35	86.97	92.19	94.86
	PPV (%)	97.38	90.97	87.07	86.82	93.87
	TCA (%)					93.57
Knn-NN ^[36]	Se (%)	94.80	58.10	88.50	88.80	74.50
	PPV (%)	98.09	74.36	78.86	54.79	78.49
	TCA (%)					
MLP network ^[37]	Se (%)	100	48.0	74.6	98.6	99.3
	PPV (%)	92.6	96.0	99.1	81.3	78.8
	TCA (%)					87.6

4 结论

面对大数据量心电信号自动分析诊断问题, 本文提出了基于深度学习和模糊分类相结合的心脏疾病诊断方法. 深度学习是目前研究最为广泛的对象特征自动提取技术, 在众多应用领域均有研究成果, 本文采用基于 RBM 构建的深度信念网络 DBN 对连续心电信号进行高层抽象特征抽取, 形成用于心律分类的特征向量数据基础, 然后结合模糊 C 均值聚类算法构建心电分类模型. 仿真实验表明: 与传统人工设计心电特征相比, 本文所提方法分类准确率更高、适应性更强. 未来工作可深入研究其他深度学习方法和分类算法相结合在心电信号自动分类中的应用, 构建多种不同的特征信号自动分析算法库。

References

- World Health Organization. Cardiovascular diseases [Online], Available: <http://www.who.int/mediacentre/factsheets/fs317/en/>, May, 2017.
- Waktare J E P, Malik M. Holter, loop recorder, and event counter capabilities of implanted devices. *Pacing and Clinical Electrophysiology*, 1997, **20**(10): 2658–2669
- de Chazal P, O'Dwyer M, Reilly R B. Automatic classification of heartbeats using ECG morphology and heartbeat interval features. *IEEE Transactions on Biomedical Engineering*, 2004, **51**(7): 1196–1206
- Pan J P, Tompkins W J. A real-time QRS detection algorithm. *IEEE Transactions on Biomedical Engineering*, 1985, **BME-32**(3): 230–236
- de Chazal P, Reilly R B. A patient-adapting heartbeat classifier using ECG morphology and heartbeat interval features. *IEEE Transactions on Biomedical Engineering*, 2006, **53**(12): 2535–2543
- Martis R J, Acharya U R, Min L C. ECG beat classification using PCA, LDA, ICA and discrete wavelet transform. *Biomedical Signal Processing and Control*, 2013, **8**(5): 437–448
- Kampouraki A, Manis G, Nikou C. Heartbeat time series classification with support vector machines. *IEEE Transactions on Information Technology in Biomedicine*, 2009, **13**(4): 512–518
- Rodríguez R, Mexicano A, Bila J, Cervantes S, Ponce R. Feature extraction of electrocardiogram signals by applying adaptive threshold and principal component analysis. *Journal of Applied Research and Technology*, 2015, **13**(2): 261–269

- 9 Ceylan R, Özbay Y. Comparison of FCM, PCA and WT techniques for classification ECG arrhythmias using artificial neural network. *Expert Systems with Applications*, 2007, **33**(2): 286–295
- 10 da S Luz E J, Nunes T M, de Albuquerque V H C, Papa J P, Menotti D. ECG arrhythmia classification based on optimum-path forest. *Expert Systems with Applications*, 2013, **40**(9): 3561–3573
- 11 Dilmac S, Korurek M. ECG heart beat classification method based on modified ABC algorithm. *Applied Soft Computing*, 2015, **36**: 641–655
- 12 Yeh Y C, Lin H J. Cardiac arrhythmia diagnosis method using fuzzy C-Means algorithm on ECG signals. In: Proceedings of the 2010 International Symposium on Computer, Communication, Control and Automation (3CA). Tainan, China: IEEE, 2010. 272–275.
- 13 Hayat M, Bennamoun M, An S J. Deep reconstruction models for image set classification. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2015, **37**(4): 713–727
- 14 Graves A, Mohamed A R, Hinton G. Speech recognition with deep recurrent neural networks. In: Proceedings of the 2013 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). Vancouver, BC, Canada: IEEE, 2013.
- 15 Al Rahhal M M, Bazi Y, AlHichri H, Alajlan N, Melgani F, Yager R R. Deep learning approach for active classification of electrocardiogram signals. *Information Sciences*, 2016, **345**: 340–354
- 16 Hinton G E, Osindero S, Teh Y W. A fast learning algorithm for deep belief nets. *Neural Computation*, 2006, **18**(7): 1527–1554
- 17 Wang Y S, Yao H X, Zhao S C. Auto-encoder based dimensionality reduction. *Neurocomputing*, 2016, **184**: 232–242
- 18 Schmidhuber J. Deep learning in neural networks: an overview. *Neural Networks*, 2015, **61**: 85–117
- 19 Kiranyaz S, Ince T, Gabbouj M. Real-time patient-specific ECG classification by 1-D convolutional neural networks. *IEEE Transactions on Biomedical Engineering*, 2016, **63**(3): 664–675
- 20 Yan Y, Qin X B, Wu Y G, Zhang N N, Fan J P, Wang L. A restricted Boltzmann machine based two-lead electrocardiography classification. In: Proceedings of the 2015 IEEE 12th International Conference on Wearable and Implantable Body Sensor Networks (BSN). Cambridge, MA, USA: IEEE, 2015. 1–9
- 21 Meng H H, Zhang Y. Classification of electrocardiogram signals with deep belief networks. In: Proceedings of the 2014 IEEE 17th International Conference on Computational Science and Engineering (CSE). Chengdu, China: IEEE, 2014.
- 22 Özbay Y, Ceylan R, Karlik B. Integration of type-2 fuzzy clustering and wavelet transform in a neural network based ECG classifier. *Expert Systems with Applications*, 2011, **38**(1): 1004–1010
- 23 Yeh Y C, Wang W J, Chiou C W. A novel fuzzy c-means method for classifying heartbeat cases from ECG signals. *Measurement*, 2010, **43**(10): 1542–1555
- 24 Sutskever I, Hinton G E. Learning multilevel distributed representations for high-dimensional sequences. *Journal of Machine Learning Research*, 2007, **2**: 548–555
- 25 Memisevic R, Hinton G. Unsupervised learning of image transformations. In: Proceedings of the 2007 IEEE Conference on Computer Vision and Pattern Recognition. Minneapolis, MN, USA: IEEE, 2007.
- 26 Bengio Y, Lamblin P, Popovici D, Larochelle H. Greedy layer-wise training of deep networks. In: Proceedings of the 19th International Conference on Neural Information Processing Systems. Cambridge, MA, USA: MIT Press, 2006. 153–160
- 27 Hüsken M, Stagge P. Recurrent neural networks for time series classification. *Neurocomputing*, 2003, **50**: 223–235
- 28 Polat K. Classification of Parkinson's disease using feature weighting method on the basis of fuzzy C-means clustering. *International Journal of Systems Science*, 2012, **43**(4): 597–609
- 29 Hwang S H, Kim D, Kang T K, Park G T. Medical diagnosis system of breast cancer using FCM based parallel neural networks. In: Proceedings of ICIC 2007: Advanced Intelligent Computing Theories and Applications with Aspects of Artificial Intelligence. Berlin Heidelberg: Springer, 2007. 712–719
- 30 Ekong V E, Onibere E A, Imianvan. Fuzzy cluster means system for the diagnosis of liver diseases. *Journal of Computer Science & Technology*, 2011, **2**(3): 205–209
- 31 Meau Y P, Ibrahim F, Narainasamy S A L, Omar R. Intelligent classification of electrocardiogram (ECG) signal using extended Kalman Filter (EKF) based neuro fuzzy system. *Computer Methods and Programs in Biomedicine*, 2006, **82**(2): 157–168
- 32 Özbay Y, Ceylan R, Karlik B. A fuzzy clustering neural network architecture for classification of ECG arrhythmias. *Computers in Biology and Medicine*, 2006, **36**(4): 376–388
- 33 Dunn J C. A fuzzy relative of the ISODATA process and its use in detecting compact well-separated clusters. *Journal of Cybernetics*, 1973, **3**(3): 32–57
- 34 Bezdek J C. *Pattern Recognition with Fuzzy Objective Function Algorithms*. New York: Springer, 1981. 203–239
- 35 Hinton G E. Training products of experts by minimizing contrastive divergence. *Neural Computation*, 2002, **14**(8): 1771–1800
- 36 Jekova I, Bortolan G, Christov I. Assessment and comparison of different methods for heartbeat classification. *Medical Engineering & Physics*, 2008, **30**(2): 248–257
- 37 Dokur Z, Ölmez T. ECG beat classification by a novel hybrid neural network. *Computer Methods and Programs in Biomedicine*, 2001, **66**(2–3): 167–181
- 吴志勇 中国海洋大学信息科学与技术学院博士研究生, 山东理工大学计算机学院讲师. 主要研究方向为智能计算. 本文通信作者. E-mail: wuzhiyong_sdut@sina.com
(WU Zhi-Yong Ph.D. candidate at the College of Information Science and Engineering, Ocean University of China. Lecturer at the School of Computer Science and Technology, Shandong University of Technology. His main research interest is intelligent computing. Corresponding author of this paper.)
- 丁香乾 中国海洋大学信息科学与技术学院教授. 主要研究方向为智能计算. E-mail: dingxq1995@vip.sina.com
(DING Xiang-Qian Professor at the College of Information Science and Engineering, Ocean University of China. His main research interest is intelligent computing.)
- 许晓伟 中国海洋大学信息科学与技术学院副教授. 主要研究方向为智能计算. E-mail: xuxw52@ouc.edu.cn
(XU Xiao-Wei Associate professor at the College of Information Science and Engineering, Ocean University of China. His main research interest is intelligent computing.)
- 鞠传香 山东理工大学计算机学院讲师. 主要研究方向为模糊数学. E-mail: chuanxiangju@sina.com
(JU Chuan-Xiang Lecturer at the School of Computer Science and Technology, Shandong University of Technology. Her main research interest is fuzzy theory.)