

本文引用格式: 陈奇志,赵沛舟,赵海全,等.基于深度学习的轨道交通变压器故障诊断方法[J].自动化与信息工程,2023,44(3):46-51.

CHEN Qizhi, ZHAO Peizhou, ZHAO Haiquan, et al. Fault diagnosis method for rail transit transformer based on deep learning[J]. Automation & Information Engineering, 2023,44(3):46-51.

## 基于深度学习的轨道交通变压器故障诊断方法\*

陈奇志<sup>1</sup> 赵沛舟<sup>2</sup> 赵海全<sup>2</sup> 蔡锦涛<sup>2</sup> 谢昌富<sup>3</sup>

(1.成都交大光芒科技股份有限公司, 四川 成都 610041

2.西南交通大学, 四川 成都 611756

3.深圳市地铁集团有限公司, 广东 深圳 518026)

**摘要:** 针对传统轨道交通变压器种类多、内部结构复杂、运行工况多样, 导致对其进行故障诊断较为困难的问题, 提出深度学习融合线性预测倒谱系数 (LPCC) 和梅尔频率倒谱系数 (MFCC) 组合特征的轨道交通变压器故障诊断方法。首先, 利用小波阈值去噪法对噪声信号预处理; 然后, 分别提取噪声信号的 LPCC 特征和 MFCC 特征, 并组合成特征向量; 最后, 将组合特征向量输入到基于深度学习的 CNN-LSTM 模型, 实现轨道交通变压器的故障诊断。实验结果表明, 该文提出的 LPCC-MFCC 组合特征和 CNN-LSTM 模型对轨道交通变压器的故障诊断准确率可达 99.48%, 精度、召回率和 F1 分数均达到 99.59%。

**关键词:** 轨道交通变压器; 故障诊断; 噪声信号分析; 特征提取; 深度学习

中图分类号: TP3

文献标志码: A

文章编号: 1674-2605(2023)03-0008-06

DOI: 10.3969/j.issn.1674-2605.2023.03.008

### Fault Diagnosis Method for Rail Transit Transformer Based on Deep Learning

CHEN Qizhi<sup>1</sup> ZHAO Peizhou<sup>2</sup> ZHAO Haiquan<sup>2</sup> CAI Jintao<sup>2</sup> XIE Changfu<sup>3</sup>

(1.Chengdu Jiaoda Guangmang Technology Co., Ltd., Chengdu 610041, China

2.Southwest Jiaotong University, Chengdu 611756, China

3.Shenzhen Metro Group Co., Ltd., Shenzhen 518026, China)

**Abstract:** In response to the problem of multiple types, complex internal structures, and diverse operating conditions of traditional rail transit transformers, which makes fault diagnosis more difficult, a deep learning fusion of linear prediction cepstrum coefficient (LPCC) and Mel frequency cepstrum coefficient (MFCC) combined features is proposed for rail transit transformer fault diagnosis. Firstly, the wavelet threshold denoising method is used to preprocess the noisy signal; Then, LPCC and MFCC features of the noise signal are extracted separately, and combined to form feature vectors; Finally, the combined feature vectors are input into the CNN-LSTM model based on deep learning to achieve fault diagnosis of rail transit transformers. The experimental results show that the proposed LPCC-MFCC combination feature and CNN-LSTM model have an accuracy of 99.48% for rail transit transformer fault diagnosis, and the accuracy, recall rate, and F1 score all reach 99.59%.

**Keywords:** rail transit transformer; fault diagnosis; noise signal analysis; feature extraction; deep learning

## 0 引言

随着轨道交通系统的快速发展, 其电力系统的安

全稳定运行要求也日趋严格。轨道交通变压器是电力系统的  
关键设备, 其故障诊断对轨道交通电力系统的

安全可靠运行具有十分重要的意义<sup>[1-2]</sup>。目前,变压器的故障诊断方法主要有振动诊断法、超声波诊断法和噪声诊断法3类。其中,振动诊断法为接触式测量法,通过将传感器紧压在待测物体的表面,可较好地避免环境噪声的干扰,但传感器会影响变压器的正常运行;超声波诊断法是利用变压器表面的超声波传感器来接收放电信号,从而达到故障定位的目的,但超声波的传输路径较为复杂,受噪声干扰影响较大,应用具有局限性;噪声诊断法是利用变压器的噪声信号识别变压器的工况,非接触式的采集方法不会对变压器的运行产生不良影响,且可以通过滤波技术来减少环境噪声的干扰,应用较为广泛。

基于深度学习的识别分类算法因学习能力强、适应性好,广泛应用于声音识别领域。文献[3]搭建了变压器铁芯振动噪声模型结构,建立基于Mel时频谱的卷积神经网络(convolutional neural network, CNN)声音识别模型,利用深度学习模型对变压器铁芯松动故障工况准确识别。文献[4]提出了一种基于卷积嵌入和线性自注意力的变压器故障诊断算法,能准确地诊断变压器故障。文献[5]利用动态时间规整对变压器噪声信号进行故障诊断。上述方法只能识别单种故障,且样本数据类型单一,有一定的局限性。

为此,本文提出深度学习融合LPCC-MFCC噪声特征的轨道交通变压器故障诊断模型。该模型提取不同类型变压器噪声信号的特征,结合基于深度学习的诊断识别算法,可准确地诊断识别轨道交通变压器的多种工况。

## 1 系统流程框架

基于CNN-LSTM的变压器故障诊断流程框架如图1所示。



图1 基于CNN-LSTM的变压器故障诊断流程框架图

首先,采集轨道交通变压器的噪声信号;然后,利用小波阈值去噪法对噪声信号进行预处理,滤除干

扰噪声;接着,以线性预测倒谱系数(linear predictor cepstral coefficients, LPCC)和梅尔频率倒谱系数(Mel-scale frequency cepstral coefficients, MFCC)的组合为特征向量,表征噪声信号的特征;最后,将LPCC-MFCC特征向量输入到CNN-LSTM模型进行故障诊断。

## 2 数据采集及小波阈值去噪

本文利用拾音设备HS-26S采集某铁路冷水牵引变电所主变压器、某地铁站牵引降压混合变电所主变压器、整流变压器和动力变压器运行时的42段噪声信号样本。采集时长5min,采样频率8kHz,采样位数16位。变压器的运行状态分为正常运行、过负荷运行、放电和直流偏磁4种。

小波阈值去噪法具有算法简单、计算速度快、适用范围广、去噪效果好等特点,适用于变压器这种含有长持续时间低频分量和短持续时间高频分量的噪声信号。小波阈值去噪参数选择如下<sup>[6]</sup>:

1) 小波函数, sym $N$ 小波有良好的正则性和对称性,由图2可知,当sym $N$ 小波的消失矩 $N$ 为8时,均方误差(mean square error, MSE)最小,去噪效果最好,故选sym8为小波函数;

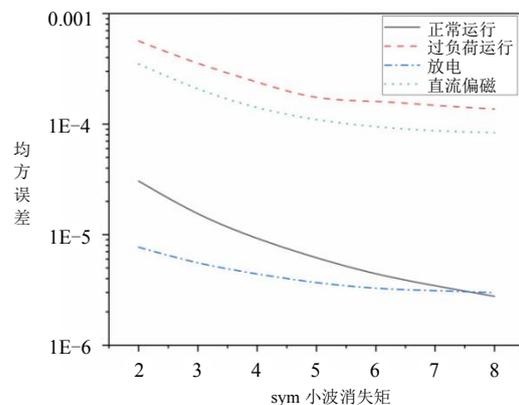


图2 不同消失矩数下的MSE

2) 确定分解层数 $M$ ,由图3可知,分解层数 $M$ 取2时,MSE最小,故选取 $M$ 为2;

3) 选择阈值,无偏似然估计阈值是一种自适应阈值的选择方法,适用于变压器噪声这类含短时高频分量、较多低频分量的信号;

4) 选择阈值函数, 本文选用硬阈值函数, 其原理是将绝对值小于给定阈值的小波系数置 0, 绝对值大于给定阈值的小波系数保留, 从而过滤掉噪声信号中的干扰成分。

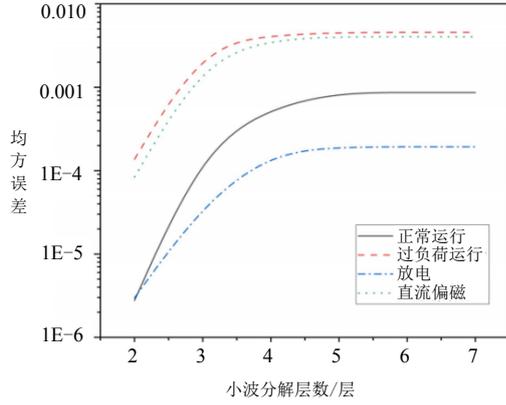


图 3 不同分解层数下的 MSE

### 3 特征提取

特征提取是从原始数据中提取有用的特征信息, 达到降维的目的, 有利于提高后续识别分类算法的泛化能力。本文分别提取噪声信号的 LPCC 和 MFCC 特征, 并将二者组合成特征向量。

#### 3.1 LPCC

LPCC 是以线性预测系数 (linear predictor coefficients, LPC) 为基础的噪声信号分析方法<sup>[7]</sup>。系统通过 LPC 分析, 获得的模型系统函数为

$$H(Z) = 1 / \left( 1 - \sum_{i=1}^p a_i z^{-i} \right) \quad (1)$$

式中:  $a_i$  为第  $i$  阶线性预测系数,  $p$  为系统的模型阶数,  $H(Z)$  为系统的传递函数,  $z$  为复变量。

将得到的 LPC, 即  $a_i$  递推到倒谱域, 由 LPC 转变到倒谱域的递推关系式为

$$\begin{cases} c_0 = a_1 \\ c_m = a_m + \sum_{k=1}^{m-1} \frac{k}{m} c_k a_{m-k}, 1 \leq m \leq p \\ c_m = \sum_{k=1}^{m-1} \frac{k}{m} c_k a_{m-k}, m > p \end{cases} \quad (2)$$

式中:  $m$  为 LPCC 的阶数,  $c_m$  为第  $m$  阶线性预

测倒谱系数。

#### 3.2 MFCC

MFCC 是根据人耳听觉特性提出来的, 具有较高的鲁棒性, 且当信噪比降低时, 仍具有较好的识别性能。MFCC 特征向量提取步骤为<sup>[8]</sup>:

- 1) 对噪声信号预处理后进行离散傅里叶变换;
- 2) 通过一组梅尔尺度的三角形滤波器组对频谱进行平滑化, 计算第  $m$  个滤波器组输出的对数能量为

$$s(m) = \ln \left( \sum_{k=1}^{N-1} |X(k)|^2 H(k) \right), 0 \leq m \leq M \quad (3)$$

式中:  $X(k)$  为各帧信号的功率谱,  $H(k)$  为能量谱通过三角滤波器得到的频率响应,  $M$  为梅尔滤波器总数,  $N$  为频域中的谱线总条数;

- 3) 进行离散余弦变换:

$$c(n) = \sum_{m=0}^{M-1} \log_{10}(s(m)) \cos \left( \frac{\pi n(m-0.5)}{M} \right) \quad (4)$$

式中:  $c(n)$  为倒谱系数,  $n = 0, 1, \dots, C-1$ ,  $C$  为 MFCC 的数量;

- 4) 计算 MFCC 的一阶、二阶差分系数, 其计算公式为

$$d_t = \begin{cases} C_{t+1} - C_t, & t < K \\ \frac{\sum_{k=1}^K k(C_{t+k} - C_{t-k})}{\sqrt{2 \sum_{k=1}^K k^2}}, & \text{其他} \\ C_t - C_{t-1}, & t \geq Q - K \end{cases} \quad (5)$$

式中:  $d_t$  为第  $t$  个一阶差分系数,  $C_t$  为第  $t$  个倒谱系数,  $Q$  为倒谱系数的阶数,  $K$  为一阶导数的时间差, 取值为 1 或 2。

差分系数体现了信号的动态特征。将 MFCC 与一阶、二阶差分系数和帧能量进行组合, 可提高识别分类系统的性能。

#### 3.3 LPCC 和 MFCC 组合

LPCC 可较大程度地去掉轨道交通变压器噪声信号的激励信息, 能近似逼近共振峰, 反映变压器的相应特性, 但其抗噪性能较差, 且无法很好地表征动态

特性；MFCC 抗噪能力强，且差分系数可以很好地表征动态特性，故将 LPCC 特征和 MFCC 特征进行组合，能更好地表征轨道交通变压器噪声信号在时域和频域的特性。在将 LPCC 特征和 MFCC 特征进行组合时，先分别获得 LPCC 和 MFCC 的特征向量，再将二者进行组合，得到 LPCC-MFCC 组合特征向量。

#### 4 CNN-LSTM 模型

本文结合 CNN 和长短期记忆 (long short-term memory, LSTM) 网络识别分类轨道交通变压器噪声信号的特点，提出一种改进模型——卷积神经网络 (CNN-LSTM) 模型，其结构如图 4 所示。



图 4 CNN-LSTM 模型结构图

CNN-LSTM 模型结构为：输入层—3 层双向 LSTM 层—卷积神经网络—全连接层—输出层。其中，卷积神经网络结构为：2 个卷积层—最大池化层—2 个卷积层—最大池化层，卷积层的激活函数为 ReLU。该模型结合了 LSTM 善于学习时序数据特征和 CNN 强大的特征提取能力的优点，能够更好地对轨道交通变压器的运行状态进行识别分类。

CNN 特征提取部分：CNN 对二维特征向量具有较强的提取能力，可有效地学习轨道交通变压器噪声信号的倒谱分布情况和局部时频特征信息。其中，局部时频特征信息是对输入的变压器噪声信号特征的抽象概括，能表达变压器同一工况下不同噪声样本的共同属性，也包括了变压器不同工况噪声信号之间的判断信息<sup>[9]</sup>。CNN 将学习获得的特征信息输入到一个全连接层，此层激活函数为 Softmax 函数，用于输出轨道交通变压器不同工况类别的概率分布，选择后验概率最大的工况类型作为最后的预测结果<sup>[10]</sup>。

CNN 层网络结构参数设置如表 1 所示。

LSTM 时序建模部分：轨道交通变压器噪声信号属于序列数据，在时间维度上不同的帧之间具有长依赖关系，此关系蕴含了重要的信息。LSTM 模块能提

取这种依赖关系，并实现前后序列特征的有效控制，使模型能很好地处理序列特征信号，故加入 LSTM 模块，以获得更好的识别准确率<sup>[11]</sup>。

表 1 CNN 层网络结构参数

层类型	通道数	核/移动步长
卷积层 Conv1、2	16	5×5/1
最大池化层	16	2×2/2
卷积层 Con3、4	32	5×5/1
最大池化层	32	2×2/2

#### 5 实验结果分析

实验采用 Python 基于 TensorFlow 和 Keras 框架搭建模型。为获得充足的样本数量以验证 CNN-LSTM 模型的性能，将 42 段时长为 5 min 的噪声样本，分割为 2 559 个时长为 5 s 的音频样本。为了验证 CNN-LSTM 模型的泛化特征能力，按照 70% 训练集、15% 验证集和 15% 测试集的比例进行分配。选用准确度 (Accuracy)、精度 (Precision)、召回率 (Recall) 和 F1 分数来评估实验结果。

将 LPCC、MFCC 和 LPCC-MFCC 3 种特征向量分别输入基于 CNN、LSTM 和 CNN-LSTM 的变压器故障诊断模型中，通过实验对比分析各项评价指标。3 种特征向量的具体参数设置为：LPCC 系数阶数为 39，系统模型的阶数为 10，得到维度为 499×39 的 LPCC；梅尔滤波器阶数为 24，FFT 变换点数为 256，39 维的 MFCC 包含 12 维标准特征和 1 维帧能量组成的 13 维静态特征、13 维的一阶动态特征和 13 维的二阶动态特征，维度为 499×39；将 39 维 MFCC 和 39 维 LPCC 组合，输入维度为 499×78。

测试集在不同特征向量和网络模型下识别的 Accuracy、Precision、Recall 和 F1 分数实验结果分别如表 2、3、4 所示。

表 2 LPCC 特征向量输入各模型测试集实验结果

网络模型	Accuracy	Precision	Recall	F1
CNN	45.14%	32.82%	36.08%	32.36%
LSTM	72.97%	86.01%	75.87%	77.19%
CNN-LSTM	84.51%	87.95%	86.17%	86.71%

表3 MFCC 特征向量输入各模型测试集实验结果

网络模型	Accuracy	Precision	Recall	F1
CNN	62.99%	49.05%	49.40%	43.67%
LSTM	79.53%	78.67%	85.66%	75.75%
CNN-LSTM	95.57%	96.49%	95.05%	95.75%

表4 LPCC-MFCC 特征向量输入各模型测试集实验结果

网络模型	Accuracy	Precision	Recall	F1
CNN	89.76%	94.06%	86.22%	89.00%
LSTM	95.01%	94.85%	96.42%	95.40%
CNN-LSTM	99.48%	99.59%	99.59%	99.59%

由表2、3、4可以看出，将3种特征向量输入到不同的网络模型进行识别分类时，LPCC-MFCC组合特征向量输入的Accuracy、Precision、Recall和F1分数较高，且当LPCC-MFCC组合特征向量输入到CNN-LSTM模型时，准确率达到99.48%，精度、召回率和F1分数均达到99.59%。

图5为验证集混沌矩阵。

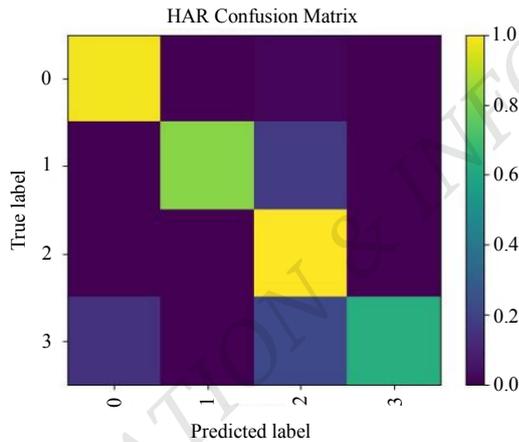


图5 验证集混沌矩阵

由图5可以看出，在对轨道交通变压器噪声信号识别分类结果中，正确分类的真正例和真负例占大多数，说明LPCC-MFCC组合特征很好地描述了轨道交通变压器运行时各工况的噪声特征，同时也验证了CNN-LSTM模型的高效性和准确性。

## 6 结论

本文提出了一种基于噪声信号的轨道交通变压

器故障诊断模型——CNN-LSTM模型，可以诊断识别出轨道交通变压器的4种工况状态，且实验证明了该模型的高效性和准确性。模型中的LPCC-MFCC组合特征向量，很好地表征了轨道交通变压器噪声信号的特征，且模型融合了CNN和LSTM的特点，既具备CNN的高维度局部特征学习能力，又具备LSTM对前后帧长时依赖关系的学习能力。但该模型计算复杂度较高，下一步可以研究如何减少模型的计算复杂度；并且由于采集的样本数据有限，不同种类变压器的故障因素多样，使实验结论具有一定的局限性，下一步可以运用数据增强技术对数据量进行扩大，提高模型的泛化能力。

## 参考文献

- [1] JIANG B, WU Y, LU N, Et al. Review of fault diagnosis and prognosis techniques for high-speed railway traction system[J]. Control and Decision, 2018, 33(5): 841-855.
- [2] 原宇博.城市轨道交通车辆制动系统控制阀故障诊断方法[J].机电工程技术, 2021, 50(2): 219-223.
- [3] 张重远, 罗世豪, 岳浩天, 等.基于Mel时频谱-卷积神经网络的变压器铁芯声纹模式识别方法[J].高电压技术, 2020, 46(2): 413-423.
- [4] Fang H, Deng J, Bai Y, et al. CLFormer: A lightweight transformer based on convolutional embedding and linear self-attention with strong robustness for bearing fault diagnosis under limited sample conditions[J]. IEEE Transactions on Instrumentation and Measurement, 2022, 71: 1-8.
- [5] 杜世斌.基于音频特征的电气设备故障监测算法研究[D].济南:山东大学, 2014.
- [6] JOSEPH S M, BABU A P. Wavelet energy based voice activity detection and adaptive thresholding for efficient speech coding[J]. International Journal of Speech Technology, 2016, 19(3): 537-550.
- [7] GUPTA H, GUPTA D. LPC and LPCC method of feature extraction in Speech Recognition System[C]. 2016 6th International Conference-Cloud System and Big Data Engineering (Confluence), 2016: 498-502.
- [8] JO J, YOO H, PARK I-C. Energy-efficient floating-point MFCC extraction architecture for speech recognition systems[J]. IEEE Transactions on Very Large Scale Integration (VLSI) Systems, 2016, 24(2): 754-758.

- [9] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. *Neural Computation*, 1997,9(8):1735-1780.
- [10] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks[J]. *Advances in Neural Information Processing Systems*, 2017, 60(6):84-90.
- [11] ABDEL-HAMID O, MOHAMED A-R, JIANG H, et al. Convolutional neural networks for speech recognition[J]. *IEEE/ACM Transactions on Audio, Speech, and Language Processing*, 2014,22(10):1533-1545.

#### 作者简介:

陈奇志, 女, 1970 年生, 工学硕士, 研究员, 主要研究方向: 轨道交通供电自动化与信息化。E-mail: qizhi.chen@cdjdg.com

赵沛舟, 男, 1998 年生, 硕士研究生, 主要研究方向: 模式识别、深度学习。E-mail: 971894367@qq.com

赵海全(通信作者), 男, 1974 年生, 博士, 教授, 主要研究方向: 自适应滤波、模式识别。E-mail: hqzhao\_swjtu@126.com

蔡锦涛, 男, 1996 年生, 工学硕士, 主要研究方向: 模式识别、深度学习。E-mail: 792780813@qq.com

谢昌富, 男, 1975 年生, 学士, 高级工程师, 主要研究方向: 城市轨道交通供电系统设备与设计管理。E-mail: 41324798@qq.com

~~~~~

(上接第 33 页)

- [2] LIN C H. Frequency-domain features for ECG beat discrimination using grey relational analysis-based classifier[J]. *Computers & Mathematics with Applications*, 2008,55(4):680-690.
- [3] CASTELLS F, RIETA J J, MILLET J, et al. Spatiotemporal blind source separation approach to atrial activity estimation in atrial tachyarrhythmias[J]. *IEEE Transactions on Biomedical Engineering*, 2005,52(2):258-267.
- [4] LEMAY M, JACQUEMET V, FORCLAZ A, et al. Spatiotemporal QRST cancellation method using separate QRS and T-waves templates[C]//*Computers in Cardiology*, 2005. IEEE, 2005:611-614.
- [5] VÁSQUEZ C, HERNÁNDEZ A, MORA F, et al. Atrial activity enhancement by Wiener filtering using an artificial neural network[J]. *IEEE Transactions on Biomedical Engineering*, 2001,48(8):940-944.
- [6] DAI H, JIANG S, LI Y. Atrial activity extraction from single lead ECG recordings: Evaluation of two novel methods[J]. *Computers in Biology and Medicine*, 2013,43(3):176-183.
- [7] ROONIZI E K, SASSI R. An extended Bayesian framework for atrial and ventricular activity separation in atrial fibrillation[J]. *IEEE Journal of Biomedical and Health Informatics*, 2016, 21(6):1573-1580.
- [8] LU J, LUO J, XIE Z, et al. Dual temporal convolutional network for single-lead fibrillation waveform extraction[J]. *Neural Computing and Applications*, 2021,33(22):15281-15292.
- [9] HINTON G, VINYALS O, DEAN J. Distilling the knowledge in a neural network[J]. *arXiv preprint arXiv:1503.02531*, 2015, 2(7).
- [10] ROMERO A, BALLAS N, KAHOU S E, et al. Fitnets: Hints for thin deep nets[J]. *arXiv preprint arXiv:1412.6550*, 2014.
- [11] STRIDH M, SORNMO L. Spatiotemporal QRST cancellation techniques for analysis of atrial fibrillation[J]. *IEEE Transactions on Biomedical Engineering*, 2001,48(1):105-111.
- [12] ALCARAZ R, SÖRNMO L, RIETA J J. Reference database and performance evaluation of methods for extraction of atrial fibrillatory waves in the ECG[J]. *Physiological Measurement*, 2019,40(7):075011.
- [13] CLIFFORD G D, LIU C, MOODY B, et al. AF classification from a short single lead ECG recording: The PhysioNet/ computing in cardiology challenge 2017[C]//*2017 Computing in Cardiology (CinC)*. IEEE, 2017:1-4.
- [14] DAI H, JIANG S, LI Y. Atrial activity extraction from single lead ECG recordings: Evaluation of two novel methods[J]. *Computers in Biology and Medicine*, 2013,43(3):176-183.

#### 作者简介:

甘兆明, 男, 1995 年生, 硕士研究生, 主要研究方向: 模式识别、机器学习、生物信号处理。E-mail: 1803158832@qq.com

林家荣, 男, 1997 年生, 硕士研究生, 主要研究方向: 模式识别、机器学习、生物信号处理。E-mail: 1440645304@qq.com