

## 基于数据驱动的设备电路板无图纸故障诊断

刘香君, 种银保, 肖晶晶, 赵鹏, 张诗慧  
陆军军医大学第二附属医院医学工程科, 重庆 400037

**【摘要】**针对医疗设备电路板结构设计复杂,传统故障诊断方法过度依赖图纸等技术资料和维修专家个人技术经验,导致维修贵、维修难等问题,提出一种基于数据驱动的无图纸故障智能诊断方法。在未知电路图纸信息以及电路板工作原理的前提下,模拟电路板不同故障状态,采集各外部接口引脚电信号作为原始故障数据;对故障数据进行预处理,并划分为训练集及测试集;使用机器学习的方法构建基于单层长短时记忆网络的故障智能诊断系统,利用Python编程进行模型训练,系统输出训练过程准确率及损失曲线。结果表明,该方法能实现对电路板故障的诊断分类,准确率达89.99%,效率较高,可靠性强。

**【关键词】**医疗设备;电路板;故障诊断;长短时记忆网络

**【中图分类号】**R318.6

**【文献标志码】**A

**【文章编号】**1005-202X(2020)08-1047-06

## Fault diagnosis for equipment circuit board based on data drive and no circuit drawing

LIU Xiangjun, CHONG Yinbao, XIAO Jingjing, ZHAO Peng, ZHANG Shihui

Department of Medical Engineering, the Second Affiliated Hospital of Army Medical University, Chongqing 400037, China

**Abstract:** Considering the complicated design of medical equipment and the problems of traditional fault diagnosis methods such as the high cost and difficulties of maintenance due to the over-reliance on technical data such as circuit drawings, as well as the personal technical experience of maintenance specialists, an intelligent fault diagnosis method based on data drive and no circuit drawing is proposed. Under the premise of unknown circuit drawing information and the working principle of the circuit board, different fault states of the circuit board were simulated, and the electrical signals of each external interface pin were collected as the original fault data which were then preprocessed and divided into training set and test set. Machine learning method was used to construct an intelligent fault diagnosis model based on a single-layer long short-term memory network. The model training was carried out by Python programming, and the accuracy curve and loss curve of training progress were output. The result showed that the proposed method realized the diagnosis and classification of circuit board faults with high efficiency and strong reliability, and the accuracy reached 89.99%.

**Keywords:** medical equipment; circuit board; fault diagnosis; long short-term memory

### 前言

医疗设备尤其是高新电子医疗设备广泛应用于疾病防治诊疗中,在现代医学中扮演着重要角色,一旦发生故障,轻则影响诊疗效率,重则威胁病患或操作人员安全,因此开展医疗设备故障诊断与维修意义重大。

传统的设备故障检测及维修方法通常是利用示波器、万用表等测试仪表,依据电路图分析其工作原理,按照信号走向在电路板上逐点寻迹的思路,借助维修经验和逻辑判断来锁定故障位置<sup>[1-2]</sup>,或者利用替换法对故障电路板进行整板替换来锁定故障位置,再对故障元器件进行检修或更换。目前,设备普遍无图纸供维修人员参考,在对设备原理及信号走向了解程度不高的前提下,逐点寻迹的方法多无从下手,且无法保证有同一型号完好备用设备供替换,替换法不一定具备现实条件,效率低下,传统故障诊断方法已不足以应对现代医疗设备发展速度和故障检修需求。

智能故障诊断技术在人工智能和机器学习不断发展的情况下,不断取得新的成绩<sup>[3-5]</sup>。其中,基于数据驱

**【收稿日期】**2020-02-20

**【基金项目】**国家重点研发计划项目(2016YFC0103100);军队卫勤专项资助项目(20WQ005)

**【作者简介】**刘香君,硕士研究生,研究方向:医疗设备故障智能诊断,  
E-mail: xiangjunl6@163.com

**【通信作者】**种银保,教授,研究方向:医疗设备故障诊断与系统维护,  
E-mail: chongyinbao@163.net

动的智能故障诊断方法在很多故障诊断领域中得到广泛应用,并取得了显著效果。该方法充分利用设备在正常和各种故障状态下的多方面数据,挖掘大量数据内潜在的有用信息,为有效准确进行故障诊断分类提供可靠支撑。特别地,基于人工神经网络的方法通常是利用大量已知分类标签的训练样本建立故障数据与故障类别的对应关系,再将测试数据输入训练好的网路进行故障诊断分类<sup>[6]</sup>。Mei等<sup>[7]</sup>在复杂操作、混合故障和强噪声情况下利用长短时记忆(Long Short-Term Memory, LSTM)网络进行故障诊断和性能预测;上官伟等<sup>[8]</sup>提出基于LSTM-BP级联网络模型的车载设备智能故障诊断方法,分类准确率达到95.1%,并验证了其有效性;周奇才等<sup>[9]</sup>提出基于改进的堆叠式循环神经网络(Recurrent Neural Network, RNN)得到轴承故障诊断模型,实现对轴承故障的有效诊断,且具有一定的可靠性和泛化能力。以上文献表明,RNN及其改进形式对各类故障诊断具有较好能力。考虑到电路板故障与上述领域故障诊断存在一定的相似相通性,为实现故障的准确有效分类,本研究拟利用端口电信号数据,采用基于LSTM网络<sup>[10]</sup>的机器学习方法来进行故障诊断。

1 理论基础

RNN是一种结构特殊的递归神经网络,以序列数据为输入,在序列演进方向进行递归并将所有循环单元链式连接,原理类似于人的现有认知受过往知识和经验影响<sup>[11]</sup>。其中,LSTM网络作为RNN的一种,由Hochreiter等<sup>[12]</sup>于1997年提出,该网络会对此前信息进行记忆并应用于当前输出的计算中,即隐藏层之间的节点有连接且隐藏层的输入不仅包括输入层的输出还包括上一时刻隐藏层的输出,赋予网络对此前知识的记忆,能很好地获取序列数据的时间信息,特别适用于序列数据处理<sup>[13]</sup>。同时,LSTM网络解决了传统RNN容易陷入梯度消失和梯度爆炸、长期记忆力不足等问题<sup>[14]</sup>。

不同于传统RNN,LSTM网络含有智能网络单元(Cell),能保存历史信息 and 长期状态(图1)。同时,LSTM单元由3种类型门控控制,即输入门、遗忘门和输出门,实现了RNN中每个时刻信息状态的有效存储和更新,使网络模型训练有效。

图1中, $i_t$ 、 $f_t$ 和 $o_t$ 分别表示输入门、遗忘门和输出门; $x_t$ 表示输入单元; $a_t$ 表示新的候选向量单元; $c_t$ 表示单元状态; $h_t$ 表示状态输出单元; $\odot$ 代表对应元素相乘; $W$ 、 $U$ 和 $b$ 分别表示网络的权重矩阵和偏置向量。各门限、单元及状态输出如式(1)~式(6)所示:

$$f_t = \sigma(W_f h_{t-1} + U_f x_t + b_f)$$

(1)

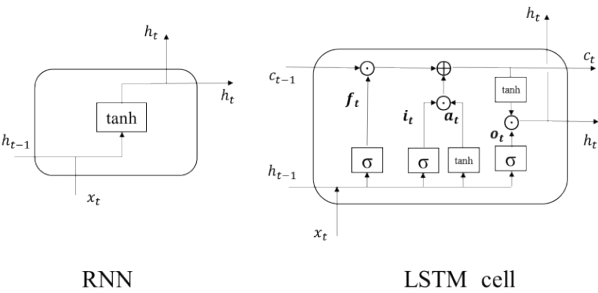


图1 长短时记忆(LSTM)网络结构示意图  
Fig.1 Schematic diagram of long short-term memory (LSTM) network structure

$$i_t = \sigma(W_i h_{t-1} + U_i x_t + b_i)$$

(2)

$$a_t = \tanh(W_a h_{t-1} + U_a x_t + b_a)$$

(3)

$$c_t = c_{t-1} \odot f_t + i_t \odot a_t$$

(4)

$$o_t = \sigma(W_o h_{t-1} + U_o x_t + b_o)$$

(5)

$$h_t = o_t \odot \tanh(c_t)$$

(6)

遗忘门是LSTM单元的关键组成部件,以一定概率控制是否遗忘和丢弃记忆单元中的信息,即根据当前输入 $x_t$ 、上一时刻状态 $c_{t-1}$ 和上一时刻输出 $h_{t-1}$ 共同决定哪一部分记忆需要被遗忘。输入门负责控制网络当前输入数据 $x_t$ 流入记忆单元的多少,将新的信息选择性地记录到新的单元状态中,同时tanh层创建一个新的候选向量 $a_t$ ,为状态更新做准备。经过遗忘门和输入门后,可以确定传递信息的新增和删除,即进行单元状态的更新。输出门控制记忆单元 $c_t$ 对当前输出值 $h_t$ 的影响,使得最后输出既包括单元状态 $c_t$ 又包括输入信息,将其结果更新到下一个单元状态。整个过程实现对无效、冗余信息的遗忘,对有效信息的保留。

2 故障诊断系统设计

本研究利用LSTM网络对医疗设备电路板进行故障诊断,总体流程如图2所示。

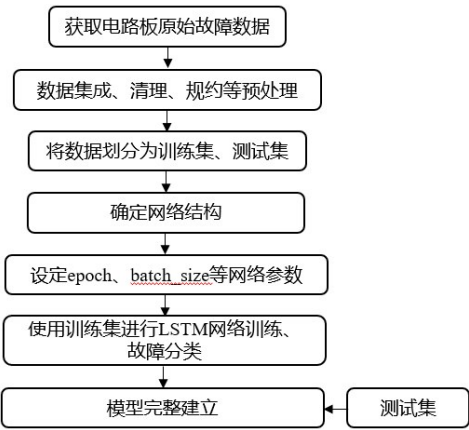


图2 基于LSTM网络的故障分类诊断流程  
Fig.2 Fault classification and diagnosis process based on LSTM network

2.1 网络结构

确定网络结构即为搭建故障诊断分类网络模型,包含输入层、LSTM网络层、dropout层、全连接层和输出层。算法步骤和各层释义如下:(1)输入层。经过预处理的序列样本数据,直接输入LSTM网络层中。(2)LSTM网络层。实验采用单层LSTM来提取特征并对网络进行训练。(3)dropout层。引入dropout层进行处理,避免隐藏层神经元特征提取的重复性,规避模型训练过程中的数据过拟合现象,增强模型泛化能力,提高网络收敛速度<sup>[15]</sup>。(4)全连接层。输出向量进入dense层进行全连接,实现特征的非线性组合。(5)输出层。输出层选用softmax多分类器,输出一个与预定义类别维数相等的向量,得到分类识别结果。

测试集输入训练好的网络模型进行结果预测,将预测值与实际值进行对比得到诊断结果,结果反向输入网络优化模块,调节模型性能参数,实现反馈调节。

2.2 网络参数设置

在文献[16-18]基础上,结合多次反复实验,为使故障诊断效果最佳,本研究的LSTM网络模型参数设置如表1所示。

表1 模型参数选取情况

Tab.1 Selection of model parameters

参数	值
序列长度	200
批大小	64
隐层神经元数	20
Dropout率	0.2
学习率	0.001
训练次数	50

3 实验过程

本实验对象为远红外电磁波辐射(YDB)-III型软组织治疗仪主控板(图3)。数据采集基于NI6216数据采集卡进行,故障诊断网络结构使用Python语言搭建。

实验对象具有响应按键控制、数模转换、输出控制、定时和显示的功能。具有7个外部接口,共45个可测试引脚。本实验在未知电路板信号走向且无电路图纸情况下,本着不介入电路板内部,不对其造成破坏的原则,以45个可及引脚作为测试点获取故障信号。多通道信号不仅能更全面反映故障类型,更能适应多种复杂情况<sup>[19]</sup>。




图3 YDB-III型软组织治疗仪主控板

Fig.3 The main control board of soft tissue therapeutic instrument YDB-III

3.1 样本数据获取及预处理

根据历史维修资料及既往经验,人为模拟6种常见硬故障外加1种正常状态,具体故障位置如图3所示,详细故障集见表2。

表2 故障设置

Tab.2 Fault settings

故障标签	故障描述			故障位置
	有无显示	按键是否有效	输出波形	
0	有	是	密疏波	正常
1	无	是	密疏波	U4故障
2	无	否	2.5 V 直流	U8故障
3	有	是	断续波	U17故障
4	有	是	疏-断续波	U16故障
5	有	是	5 V 直流	U6故障
6	有	是	0.3 V 直流	U14故障

在处方3(正常输出为密疏波)、强度100的条件下,通过LabVIEW编写基于多块NI6216采集板卡的程序,如图4所示,分别同时采集各接口各引脚电信号(依次标记为V0~V44)。采集频率3 kHz,每种故障采集时间为5 s,获取7组数据,共105 000个数据点。以故障0为例,45路信号波形如图5所示,可以看到各接口信号有明显差异。

将7组故障数据进行集成归约整理至一个数据集。考虑到45路信号幅值各不相同,直接使用原始数据进行网络训练,突出幅值较高信号的作用,削弱幅值较低信号的作用。为保证结果有效可靠,对原始数据进行标准的归一化处理<sup>[20]</sup>。



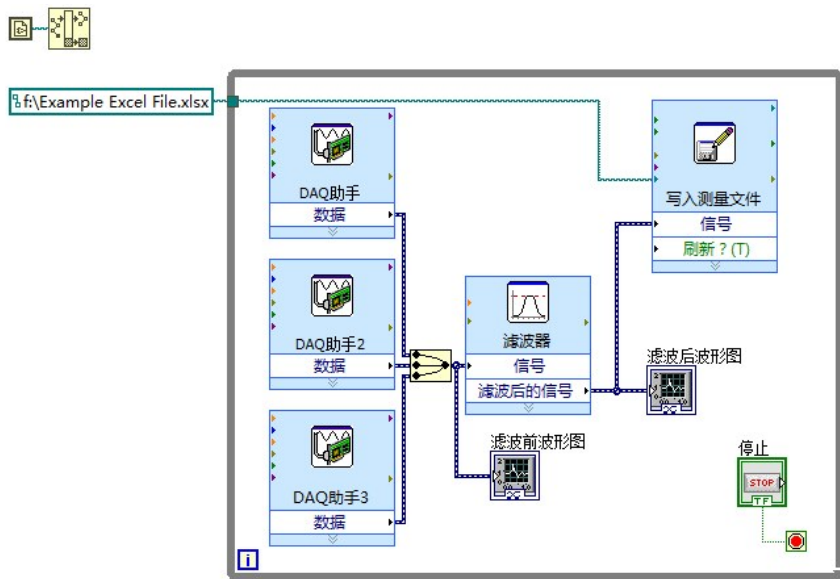


图4 数据采集LabVIEW程序

Fig.4 LabVIEW program for data acquisition

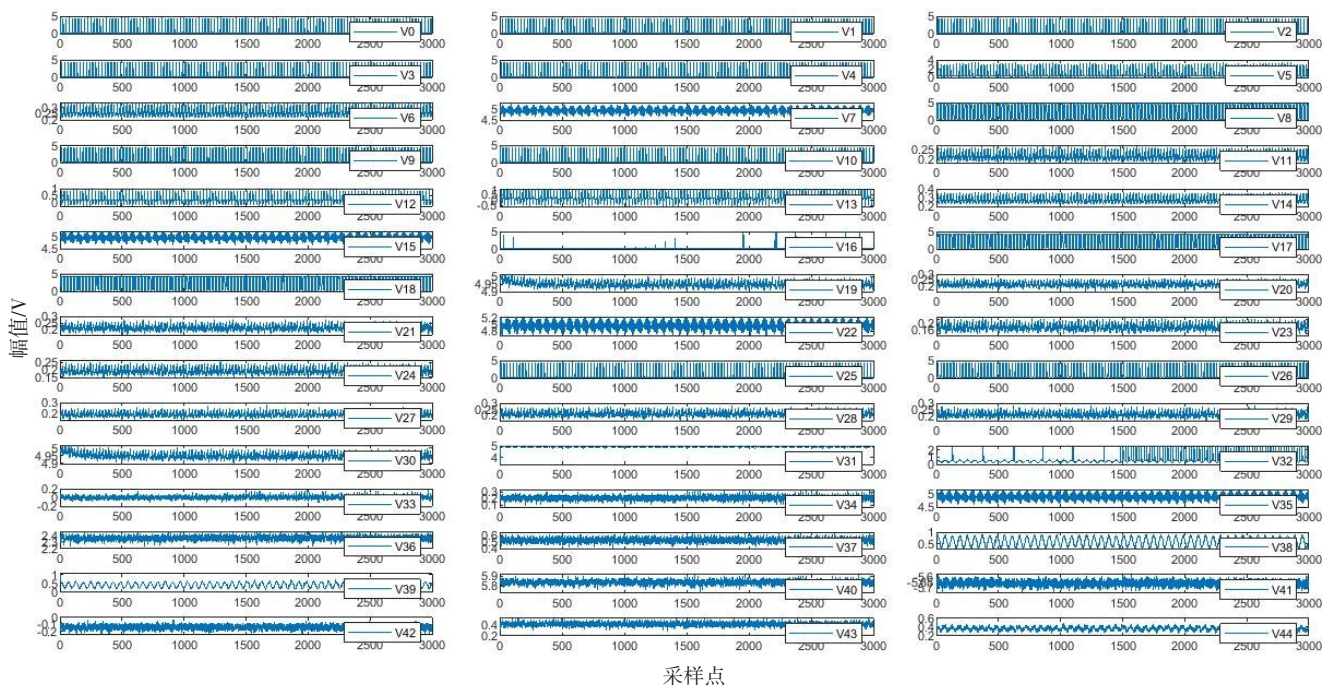


图5 电路板故障0状态下各接口信号示例

Fig.5 Examples of circuit board interface signals in the state of fault 0

将预处理后的数据以 200 个连续采集点划分为一个样本,实验所采集的 105 000 个数据点共划分为 525 个样本。乱序后按 4:1 的比例随机分为训练集和测试集,分别得到样本数为 420 的训练数据集和样本数为 105 的测试数据集,以此作为诊断模型的输入。

3.2 实验结果及分析

实验训练过程的 loss 曲线及准确率随迭代次数的变化情况如图 6 所示,可以看出,经过 50 次迭代训练,模型诊断分类准确率为 91.43%。

为评价模型对不同故障的分类效果,分别计算每类故障的查准率( $P$ )、查全率( $R$ )、 $F1$  值、ROC 曲线下面积(AUC)等指标值,具体结果如表 3 所示。

为避免实验结果的偶然性,在同一数据源、相同参数和处理步骤下重复进行 5 次实验,具体结果如表 4 所示。

由表 3 各项评价指标可知:在单次诊断实验中,测试集各类故障样本数相对平均,根据实际样本数与预测样本数,其中标签为 0、1、2、5 这 4 种故障均实现 100% 准确分类,标签为 3、4、6 的 3 种故障不同程度的有误诊




图6 训练过程损失及准确率曲线

Fig.6 Loss and accuracy curves of training process

表3 故障诊断分类结果

Tab.3 Classification results of fault diagnoses

故障标签	实际样本数	预测样本数	查准率(P)	查全率(R)	F1值	AUC
0	13	13	0.93	1.00	0.96	1.00
1	12	12	1.00	1.00	1.00	1.00
2	12	12	1.00	1.00	1.00	1.00
3	20	13	1.00	0.65	0.79	0.94
4	21	20	0.83	0.95	0.89	0.97
5	14	14	1.00	1.00	1.00	1.00
6	13	12	0.75	0.92	0.83	1.00
合计/均值	105	96	0.93	0.91	0.91	0.99

表4 实验结果(%)

Tab.4 Experimental results (%)

指标	实验次数					均值±标准差
	1	2	3	4	5	
准确率	91.43	87.62	90.48	90.74	92.38	89.99±0.021

断情况出现,但错误率较低,模型总体诊断分类准确率为91.43%,查准率、查全率、F1值及AUC分别为0.93、0.91、0.91、0.99;由表4实验结果总体可知:使用LSTM方法对软组织治疗仪主控板故障进行诊断分类,稳定性较好,准确率高,平均诊断准确率达89.99%。

4 结 论

本研究针对无图纸医疗设备电路板,应用NI6216采集板卡从电路板外部接口各引脚对其进行非侵入式故障电信号数据采集;使用机器学习的方

法,通过构建LSTM网络模型对故障进行诊断分类识别。经过实验分析,结果表明:LSTM网络模型能在医疗设备电路板故障诊断分类识别中达到较好效果,准确率可达89.99%,具有良好的可行性和可靠性。

下一步将围绕如何提高故障诊断分类识别准确率的总体目标,通过扩充样本数、叠加其他故障信息、调节网络模型参数、对比其他智能诊断方法等,进一步优化网络模型,为使用LSTM网络对医疗设备电路板故障诊断提供支撑和依据。

【参考文献】

[1] 童斌. 医疗设备维修管理的几点问题与对策[J]. 医疗卫生装备, 2010, 31(1): 99-100.

TONG B. Some problems and countermeasures for medical equipment maintenance management [J]. Chinese Medical Equipment Journal, 2010, 31(1): 99-100.

[2] 种银保. 临床工程师规范化培训教程[M]. 北京: 科学出版社, 2017.

CHONG Y B. Standardized training course for clinical engineers [M]. Beijing: Science Press, 2017.

[3] 李晗, 萧德云. 基于数据驱动的故障诊断方法综述[J]. 控制与决策, 2011, 26(1): 1-9.

LI H, XIAO D Y. Survey on data driven fault diagnosis methods [J]. Control and Decision, 2011, 26(1): 1-9.

[4] 陈伟宏, 安吉尧, 李仁发, 等. 深度学习认知计算综述[J]. 自动化学报, 2017, 43(11): 1886-1897.

CHEN W H, AN J X, LI R F, et al. Review on deep-learning-based cognitive computing [J]. Acta Automatica Sinica, 2017, 43(11): 1886-1897.

[5] DALLY W J, GRAY C T, POULTON J, et al. Hardware-enabled artificial intelligence [C]//2018 IEEE Symposium on VLSI Circuits, 2018: 3-6.

[6] SCHMIDHUBER J. Deep learning in neural networks [M]. Amsterdam: Elsevier Science Ltd, 2015.

[7] MEI Y, WU Y, LI L. Fault diagnosis and remaining useful life

- estimation of aero engine using LSTM neural network [C]//IEEE International Conference on Aircraft Utility Systems, 2016: 135-140.
- [8] 上官伟, 孟月, 杨嘉明, 等. 基于LSTM-BP级联网络的列控车载设备故障诊断[J]. 北京交通大学学报, 2019, 43(1): 59-67.  
SHANGGUAN W, MENG Y Y, YANG J M, et al. LSTM-BP neural network based fault diagnosis for on-board equipment of Chinese train control system[J]. Journal of Beijing Jiaotong University, 2019, 43(1): 59-67.
- [9] 周奇才, 沈鹤鸿, 赵炯, 等. 基于改进堆叠式循环神经网络的轴承故障诊断[J]. 同济大学学报(自然科学版), 2018, 47(10): 1500-1507.  
ZHOU Q C, SHEN H H, ZHAO J, et al. Bearing fault diagnosis based on improved stacked recurrent neural network[J]. Journal of Tongji University (Natural Science), 2018, 47(10): 1500-1507.
- [10] 杨丽, 吴雨茜, 王俊丽, 等. 循环神经网络研究综述[J]. 计算机应用, 2018, 38(S2): 6-11.  
YANG L, WU Y Q, WANG J L, et al. Research on recurrent neural network[J]. Journal of Computer Applications, 2018, 38(S2): 6-11.
- [11] GRAVES A. Supervised sequence labelling [M]. Heidelberg: Springer Berlin Heidelberg, 2012, 385(2): 5-13.
- [12] HOCHREITER S, SCHMIDHUBER J. Long short-term memory [J]. Neural Computation, 1997, 9(8): 1735-1780.
- [13] 阚威, 李云. 基于LSTM的脑情绪识别模型[J]. 南京大学学报(自然科学), 2019, 55(1): 116-122.  
KAN W, LI Y. Emotion recognition from EEG signals by using LSTM recurrent neural networks [J]. Journal of Nanjing University (Natural Science), 2019, 55(1): 116-122.
- [14] WANG W F, QIU X H, CHEN C S, et al. Application research on long short-term memory network in fault diagnosis [C]//2018 International Conference on Machine Learning and Cybernetics (ICMLC), 2018.
- [15] 钟欣, 陈恩晓, 罗瑞奇, 等. 多尺度融合dropout优化算法[J]. 华中科技大学学报(自然科学版), 2018, 46(9): 35-39.  
ZHONG X, CHEN E X, LUO R Q, et al. Multi-scale fusion dropout optimization algorithm [J]. Journal of Huazhong University of Science and Technology (Natural Science Edition), 2018, 46(9): 35-39.
- [16] 尚钢, 钟路. 神经网络结构与训练参数选取[J]. 武汉工业大学学报, 1997, 2: 108-110.  
SHANG G, ZHONG L. Discussion about BP neural network structure and choice of samples training parameter [J]. Journal of Wuhan University of Technology, 1997, 2: 108-110.
- [17] PASCANU R, MIKOLOV T, BENGIO Y. On the difficulty of training recurrent neural networks [C]//30th International Conference on Machine Learning(ICML), 2013.
- [18] LIN X, MAO Y C, BAO Y S, et al. Open-circuit fault diagnosis of power rectifier using sparse autoencoder based deep neural network [J]. Neurocomputing, 2018, 311(15): 1-10.
- [19] 姜月, 邹任玲. 基于多特征融合的运动想象脑电信号识别研究[J]. 中国医学物理学杂志, 2019, 36(5): 100-106.  
JIANG Y, ZOU R L. Recognition of motor imagery EEG signals based on multi-feature fusion [J]. Chinese Journal of Medical Physics, 2019, 36(5): 100-106.
- [20] 汤荣志, 段会川, 孙海涛. SVM训练数据归一化研究[J]. 山东师范大学学报(自然科学版), 2016, 31(4): 60-65.  
TANG R Z, DUAN H C, SUN H T. Research on data normalization for SVM training [J]. Journal of Shandong Normal University (Natural Science Edition), 2016, 31(4): 60-65.

(编辑:谭斯允)