

DOI: 10.13382/j.jemi.B2104241

基于 LSTM 的电子系统间歇故障严重程度识别方法*

李 晟 邓江云 周兴龙 李玉晓 徐飞洋

(江西理工大学理学院 赣州 341000)

摘要: 间歇故障的累积会导致电子系统健康状态退化, 正确识别电子系统间歇故障严重程度是保障系统安全运行、降低维护成本的关键。针对间歇故障特征难以准确提取导致传统识别方法失效的问题。本文提出了一种基于长短期记忆(LSTM)网络的间歇故障严重程度识别方法, 首先将间歇故障注入电子系统获取足量不同严重程度的训练数据。再用这些数据训练由 LSTM 网络与 softmax 全连接层网络构建的严重程度识别模型。最后, 通过对典型电路的故障注入, 使用训练好的 LSTM 网络对间歇故障严重程度进行识别, 实验结果证明了方法的有效性和可行性。

关键词: 长短期记忆; 间歇故障; 电子系统; 故障严重程度; 故障注入

中图分类号: TN407

文献标识码: A

国家标准学科分类代码: 510.4010

Intermittent fault severity recognition method for electronic systems based on LSTM

Li Sheng Deng Jiangyun Zhou Xinglong Li Yuxiao Xu Feiyang

(School of Science, Jiangxi University of Science and Technology, Ganzhou 341000, China)

Abstract: The accumulation of intermittent faults will cause the deterioration of the health of the electronic system. Correctly identifying the severity of intermittent faults can ensure the safe operation and reduce maintenance costs of the electrical systems. However, it is difficult to extract intermittent fault features accurately, which leads to the failure of traditional identification methods. This paper proposes a method for identifying the severity of intermittent faults based on LSTM network. First, the intermittent faults are injected into the electronic system to obtain sufficient training data of different severity. Then use these data to train the classifier which is constructed by LSTM network and the softmax fully connected layer network. Finally, by injecting faults into typical circuits and using the trained LSTM network to identify the severity of intermittent faults, the experimental results prove the effectiveness and feasibility of the method.

Keywords: long short-term memory(LSTM); intermittent fault; electronic system; fault severity; fault injection

0 引言

随着电子技术的发展, 电子系统复杂度不断提高, 给电子系统故障预测以及健康管理(prognostics and health management, PHM)带了巨大的挑战^[1]。间歇故障(intermittent faults, IFs)是电子系统故障的主要来源, 是电子系统永久故障的前兆, 其主要来源是电子系统运行过程中不可避免出现的老化、磨损、材料应变等^[2]。根据 IEEE 1234-2019 的标准, 间歇故障是由相同的原因重复出现的故障, 具有在有限的时间内持续, 且在无外界干扰

的情况下自行恢复的特性^[3]。随着时间的推移, 间歇故障的故障严重程度会逐渐增大, 使得系统健康状态退化, 最终演变为永久性故障(permanent faults, PFs)导致系统完全失效。因此, 准确识别间歇性故障严重程度是对电子系统健康状态进行有效表征和评估的关键。

针对间歇故障诊断问题, 文献[4]运用无下采样离散小波变换(undecimated discrete wavelet transform, UDWT)的方法识别永磁交流电驱动器当中的间歇性电阻故障。Cai 等^[5-6]将动态贝叶斯网络(dynamic Bayesian network, DBN)运用到了间歇故障的种类以及位置辨识过程, 取得了较好的效果。文献[7]提出决策森林方法,

收稿日期: 2021-04-30 Received Date: 2021-04-30

* 基金项目: 国家自然科学基金(11875149, 61565007, 61762047)项目资助

在对发动机/变速箱控制模块的电子控制单元 (electronic control unit, ECU) 间歇故障辨识过程中,取得了很好的效果,文献[8]利用一种改进卷积深度神经网络实现了对轴承故障的有效诊断,但以上方法均不能有效识别电子系统间歇故障严重程度。

为了准确识别间歇故障严重程度,更好地预测电子系统的剩余寿命,许多学者提出了对比健康信号与故障信号的差异,从中提取能够表征间歇故障“严重性”的特征,并利用这些特征训练识别模型。Li 等^[9]利用小波变换提取间歇故障特征,通过小波系数提取信号能量,得到间歇故障“严重性”特征,可用于识别和隔离间歇故障。Zhang 等^[10]引入软测量模型,通过残差分析提取间歇性传感器故障的“严重性”特征。但电路退化是故障严重程度随时间变化过程,以上方法均缺乏对间歇故障严重程度对时间累积的描述,因此无法有效识别退化过程中的故障严重程度动态变化。Li 等^[11]利用特征选择验证 (feature selective validation, FSV) 构建特征故障“严重程度因子”,并利用该特征训练隐半马尔科夫模型 (hidden semi-Markov model, HSMM),利用 HSMM 模型极强的对时间序列建模和时序模式分类能力实现电路健康状态的识别及剩余使用寿命预测,达到了很好的效果。但由于 HSMM 的观测状态必须是离散的整数序列,对连续数据进行量化会导致信息的损失,使得该方法的泛化性能不足。

长短期记忆 (long short-term memory, LSTM) 神经网络是一种改进的循环神经网络 (recurrent neural network, RNN),为解决 RNN 的梯度爆炸和梯度消失问题而被提出。LSTM 对时间序列前后相关性极其敏感,因此 LSTM 网络可以有效捕获复杂时序数据中的长期依赖信息,能够很好的适用于间歇故障严重程度演变过程。且 LSTM 的特征捕获能力强、鲁棒性良好、易于训练,近年来在时变参数辨识、故障诊断等领域都获得了成功的应用^[12-14]。

综上所述,目前对于间歇故障的诊断方法存在样本难以获取、故障数据特征难以提取等问题,多数方法需要复杂的先验知识,泛化性差。基于此,本文针对间歇故障严重程度的演变过程,提出了一种基于 LSTM 网络的电子系统间歇故障严重程度识别方法。首先通过对电子系统的间歇性电阻故障注入获取足量的间歇故障训练数据;其次,对不同严重程度的间歇故障数据进行标注,并输入 LSTM 网络中进行训练得到模型参数,在训练过程中对网络的特定层采用 dropout 处理^[15]以防止网络出现过拟合现象;再利用训练好的 LSTM 网络对实际电子系统的间歇故障进行严重程度识别;最后通过实验测试了所提方法对 ECG 后级放大电路间歇故障严重程度的识别准确率,验证了本文所提方法的可行性和有效性。

1 间歇故障注入

1.1 间歇故障机理分析

电子系统间歇故障的成因机理复杂多样,其中焊盘或其他电连接器的老化是导致间歇故障的主要原因,该类间歇故障主要表现为焊盘或连接器电阻值的间歇性随机突变。焊盘或物理连接老化的成因机理主要是氧化和松动开裂,氧化的成因是较为极端的温度、湿度,导致金属连接器表面生成氧化膜,失去了原有的导电性,且随着时间的推移,连接处氧化层的覆盖面积不断增大,导致电阻值发生变化,其退化过程如图 1 所示。

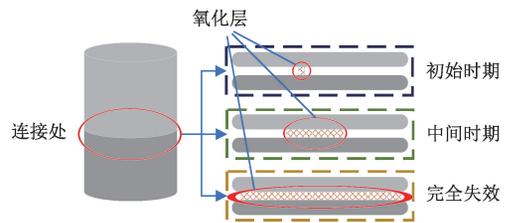


图 1 电子系统焊盘氧化过程

Fig. 1 Electronic system pad oxidation process

焊盘的松动开裂主要是由外部应力导致的,当电路系统连接处的材料受到一定的外力时会产生弹性形变,而当外力超过一定范围或是长时间受到外力影响时,弹性形变就会转换为塑性形变,并最终导致连接处出现松动、断裂,而其形变的程度会随着时间慢慢积累,印制电路板中由外力而导致焊盘开裂的情况如图 2 所示。

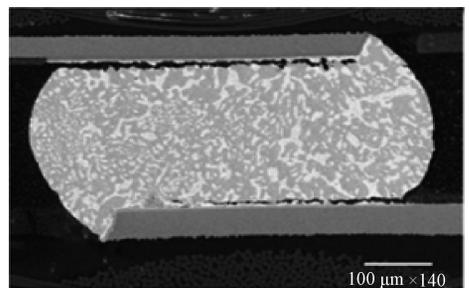


图 2 PCB 上开裂的焊盘

Fig. 2 Cracked pads on the PCB

无论是氧化还是松动开裂,最终表现为焊盘或物理连接处的电阻值发生间歇性随机突变,且随着时间推移,间歇电阻故障的严重程度会在电子系统的退化过程中不断增大,具体表现为故障发生频率及电阻值的大小不断升高^[16],在电阻的退化周期当中,不同阶段电阻值所处的间歇故障严重程度的动态演变过程如图 3 所示。

1.2 间歇故障注入方法

电子系统间歇故障具有间歇性、随机性和自恢复性

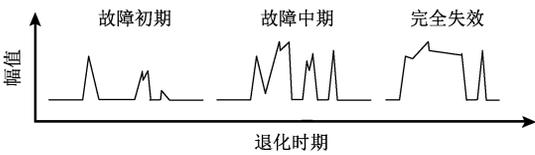


图3 电子系统间歇故障严重程度演变过程

Fig. 3 Evolution of the severity of intermittent faults in electronic systems

的特点,尤其是在故障发生的早中期,由于发生频率低、电阻变化小、持续时间短 ($10^{-9} \sim 10^{-6}$ s),使得间歇故障难于监测,获取足量训练数据困难。加速退化仿真实验是获取训练样本的有效手段,本文利用文献[11]中建立的间歇电阻故障注入模型以及相应的故障注入器,对电子系统故障注入并获取足量不同严重程度的故障训练样本。要进行准确的间歇故障注入,必须建立准确的间歇故障模型。

如图4所示是采用四线测电阻法实际测量得到的间歇故障发生时,电阻值的随机变化过程,根据所显示的接触电阻随时间变化的数据,一个完整的间歇故障周期包括一个“故障周期”(T_{safe})和一个“非故障周期”(T_{fault})。

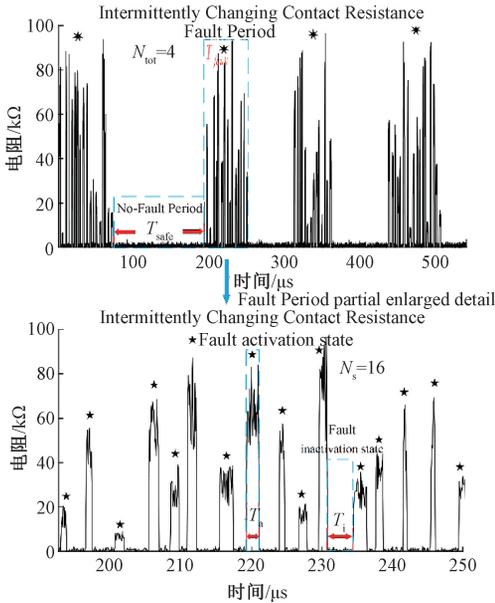


图4 实测间歇性接触电阻变化

Fig. 4 Measured intermittently changing contact resistance changes

接触电阻 R_f 在“故障期间”的状态下间歇地急剧变化,在“非故障期间”的状态下恢复为正常值。“故障周期”由两个状态组成:接触电阻急剧增加的故障激活状态(T_a)和恢复了正常接触电阻的故障失活状态(T_i)。间歇性故障将在故障激活状态和故障失活状态之间反复切换,每个故障周期中的过渡周期数用 N_s 表示, N_{tot} 代表“失效期”的总数。所有相关参数的统计结果显示在表1中。根据表1的统计数据,建立间歇故障模型,以模拟引起电子设备中接触电阻的变化。建模过程如图5所示,

其中, N_s 、 T_a 、 T_i 和 T_{safe} 根据分布的概率函数随机生成。

表1 间歇电阻故障参数取值区间及分布规律

Table 1 Intermittent resistance fault parameter value interval and distribution law

参数	最小值	最大值	概率分布
$R_f/k\Omega$	0	100	均匀分布
T_a	100 ns	2 μ s	均匀分布
T_i	100 ns	10 μ s	均匀分布
T_{safe}	50 μ s	1 ms	均匀分布
N_s	1	20	均匀分布

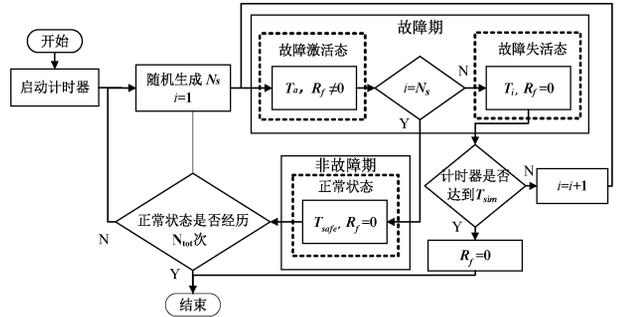


图5 间歇电阻故障模型

Fig. 5 Intermittent resistance fault model

2 长短期记忆人工神经网络结构

LSTM 网络是一种时间循环神经网络,与 RNN 一样,该网络对当前时刻之前的数据具有一定的记忆功能,对数据序列的前后关系的特征捕获能力较强。作为 RNN 的一种变体,LSTM 网络引入门控结构解决了 RNN 因梯度爆炸或梯度消失所造成的难以保持对时间序列长时间记忆^[17]的问题。

2.1 LSTM 网络

LSTM 网络中的短时记忆单元功能类似于 RNN 中的隐藏层,并且两者的输入层结构相同。与 RNN 简单的单向交互不同,LSTM 网络引入遗忘门(forget gate)、输入门(input gate)、输出门(output gate)3个特殊的门来控制信息的存储与输出,其基本单元结构如图6所示。

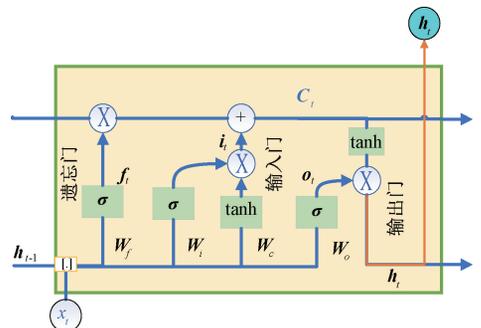


图6 LSTM 基本单元结构

Fig. 6 LSTM basic unit structure

图 6 中 σ 表示 sigmoid 激活函数, \tanh 表示双曲线正切激活函数。由图 6 可知, LSTM 网络由细胞单元构成, 每个细胞单元的参数完全相同, 并分别负责处理某一时刻 t 当中的输入数据 x_t 。LSTM 网络某一时刻的输出不仅和该时刻的输入向量以及上一时刻的隐藏层向量 (h_{t-1}) 有关, 还与细胞单元状态 C_t 有关。一个 LSTM 网络的细胞单元包含 4 个门控结构: 1) 遗忘门决定了应当从之前的细胞当中遗忘多少信息, 以及保留多少信息, 该功能通过将细胞单元状态与 sigmoid 函数的输出值相乘来实现, 经过 sigmoid 函数变换的输出向量 f_t 中每一个元素的值介于 0~1 之间, 0 表示完全丢弃, 1 表示完全保留。2) 输入门的 sigmoid 函数部分决定了应当如何更新细胞状态。3) 输入门的 tanh 函数创建候选向量, 并添加到细胞状态当中。4) 输出门决定如何输出信号当中有用的信息。

在使用 LSTM 网络处理数据时, 首先需要将原始数据 x 进行归一化, 归一化公式为:

$$\hat{x} = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (1)$$

每个 LSTM 网络细胞单元的输入层 t 时刻的输入为长度固定的向量, 用 \hat{x}_t 表示, 则遗忘门输出向量由式 (2) 给出:

$$f_t = \text{sigmoid}(W_f \cdot [h_{t-1}, \hat{x}_t] + b_f) \quad (2)$$

式中: h_{t-1} 是 $t-1$ 时刻细胞单元的隐藏层向量, \hat{x}_t 表示 t 时刻的输入向量。 W_f 为遗忘门中的权重矩阵, 而 b_f 则表示偏置向量。

输入门输出向量 i_t 与输出门的输出向量 o_t 分别为:

$$i_t = \text{sigmod}(W_i \cdot [h_{t-1}, \hat{x}_t] + b_i) \cdot \tanh(W_c \cdot [h_{t-1}, \hat{x}_t] + b_c) \quad (3)$$

$$o_t = \text{sigmoid}(W_o \cdot [h_{t-1}, \hat{x}_t] + b_o) \quad (4)$$

其中, $W_i, W_c, W_o \in R^{k \times d}, b_i, b_c, b_o \in R^d$ 分别代表相应的权重矩阵以及偏置向量, d 为向量 $[h_{t-1}, \hat{x}_t]$ 维数, k 为向量 C_t 维数, “ \bullet ”表示向量点乘, “ \cdot ”表示矩阵乘积。 i_t 表示 t 时刻细胞单元状态添加的新信息, 通过将 i_t 与 C_t 相加来达到更新第 t 个细胞状态的目的, 综上所述, 更新细胞单元状态的公式如下:

$$C_t = f_t \bullet C_{t-1} + i_t \quad (5)$$

隐藏层向量 h_t 作为 LSTM 网络每一个细胞单元最终的输出, 并由输出门和细胞单元状态共同决定, 其表达式如下。

$$h_t = o_t \bullet \tanh(C_t) \quad (6)$$

LSTM 网络由基本细胞单元构成, 网络结构如图 7 所示。

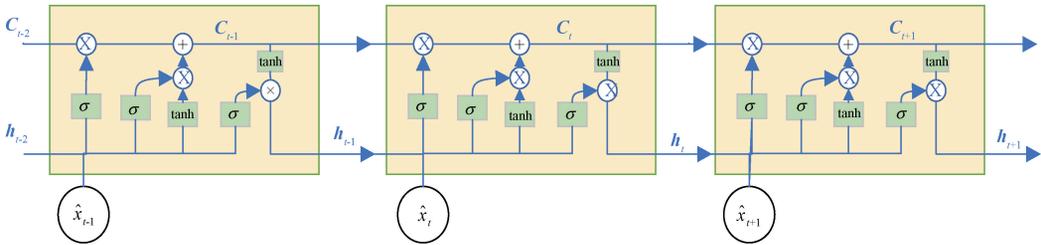


图 7 LSTM 网络结构

Fig. 7 LSTM network structure

LSTM 网络可用作对于时间序列的回归分析以及分类, 其训练算法均采用有监督学习的方式, 利用反向传播算法进行训练^[18]。当 LSTM 被用于间歇性故障严重程度分类时, LSTM 网络的输出是最后一个细胞单元的隐藏层向量。

2.2 softmax 模型

softmax 模型是 logistic 模型的推广, 它能够任意实数范围内的向量 z 映射到区间 $[0, 1]$ 内, 并且能够将某一层上神经元的输出概率值转化为互斥的概率事件, 以 softmax 层作为输出层的全连接层网络结构如图 8 所示。

softmax 层的输出值按式 (7) 计算:

$$y_i = \frac{e^{z_i}}{\sum_{j=1}^N e^{z_j}} \quad (7)$$

其中, y_i 表示该神经元经过变换之后的输出值, N 表示该网络的输出层神经元个数。 z_i 表示 softmax 层在经过柔性归一化之前每个神经元的输出概率, 其值由输入向量以及网络参数得到:

$$z = (h_t \bullet W_1 + b_1) \bullet W_2 + b_2 \quad (8)$$

式中: W_1, W_2, b_1, b_2 分别表示各层网络之间的权重矩阵与偏置向量。

2.3 dropout 层

在模型的训练过程中, 若训练样本数量较少, 同时模型参数较多, 经过训练的模型就容易产生过拟合现象, 具

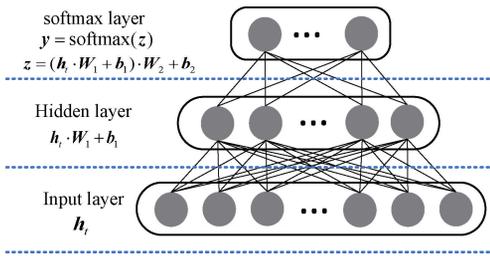


图 8 全连接层网络结构

Fig. 8 Fully connected layer network structure

体表现为模型在训练集上的识别准确率较高,而在测试集上识别准确率较低。利用 dropout 层可以有效减少模型的过拟合,防止训练数据发生复杂的协同适应。在每个周期的训练过程当中,dropout 对上一层神经元进行处理,使其中的每个单元以 0.5 的概率从网络中随机删除,被删除的单元不参与损失函数的计算(前向传播),并且在本次反向传播的过程中对应权值与偏置保留上一次计算结果,不参与更新。而未被删除的神经元则按照原来的方式进行前向概率的计算以及参数更新,因此在每个训练周期当中,dropout 层中只有部分神经元参与训练。

3 基于 LSTM 网络的间歇故障严重程度识别方法

单独的 LSTM 循环神经网络不具备对时间序列进行分类的能力,本文在 LSTM 网络后外接 softmax 全连接层网络进行分类。由 LSTM 网络与 softmax 全连接层网络搭建而成的分类器结构如图 9 所示。其中,dropout 层的作用是在训练时对全连接层中的神经元进行随机选取并输出至 softmax 层进行分类,而在识别过程中则不需要 dropout 层的参与。

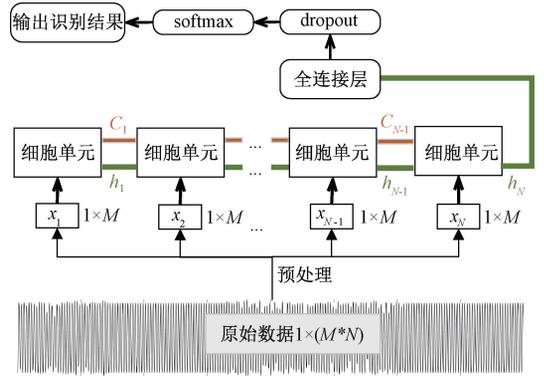


图 9 LSTM 网络分类器

Fig. 9 LSTM network classifier

由于每一个 LSTM 网络细胞单元的输入向量长度是定值 M ,数据序列在被输入进 LSTM 多分类网络之前需要经过预处理,包括归一化和分段。归一化之后的数据被分割为 N 段等长的序列,其中每一段的长度固定为 M 。按照前后顺序将每一段数据输入 LSTM 网络当中,并根据网络权重与偏置向量求取整个网络的输出值。采用以损失函数应最小为准则的反向传播算法训练 LSTM 网络,损失函数定义如下:

$$R = -\frac{1}{n} \sum_n \| y_0 \ln y + (1 - y_0) \ln(1 - y) \| \quad (9)$$

其中, y 表示由网络计算得到数据的标签(故障的状态类别,为 0~1 之间的概率值),而 y_0 则表示数据实际的标签。需要注意的是,输入至 LSTM 网络中的序列长度必须为细胞单元输入层长度的整数倍,而序列中的元素可以是任意连续的概率值,识别结果即为 softmax 层中被激活的神经元(概率值最大)所对应的类别。综上所述,本文提出的基于 LSTM 网络的间歇故障严重程度识别方法流程如图 10 所示。

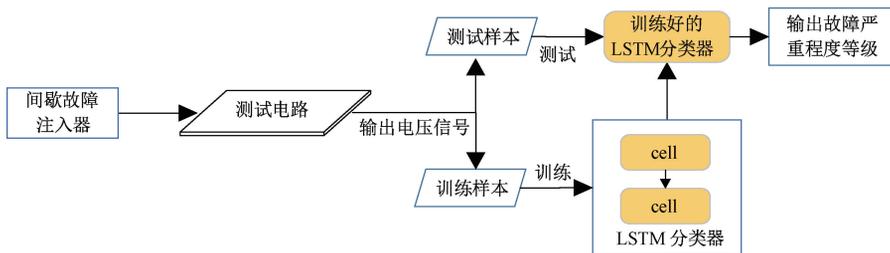


图 10 基于 LSTM 网络的间歇故障严重程度识别过程

Fig. 10 Recognition process of intermittent fault severity based on LSTM network

基于 LSTM 网络的间歇故障严重程度识别方法步骤如下:

1) 利用故障注入器将不同故障严重程度的间歇电阻故障注入被测电路。

2) 从被测电路中采集在不同严重程度的间歇故障注入下的响应信号(一般为电压信号),并做好标注,将标注好的样本分为训练集以及测试集。

3) 利用训练集当中的不同故障严重程度的数据对

LSTM 网络进行有监督学习,得到其模型参数。

4) 将测试集当中的样本数据输入已经训练好的 LSTM 网络当中进行间歇故障严重程度识别,并与不同故障严重程度标注进行对比,分析分类器的性能。

4 实验

4.1 实验案例

将心电仪的 ECG 后级放大电路作为研究对象,利用文献[11]的间歇故障注入器对特定位置的焊盘进行间歇故障注入,通过修改间歇故障参数安全时长(T_{safe})以及单位周期内间歇故障发生次数(N_s)来划分故障严重程度等级并进行标注。实验将严重程度划分为 8 个等级,随着等级的提升,故障严重程度不断升高,故障参数设置如表 2 所示。实验环境使用到的设备包括:泰克 MD3024 数字示波器;直流电源;泰克 AFG31000 系列任意波形发生器;由 FPGA 控制的间歇故障注入器;被测电路。被测电路的输入信号由任意波形函数发生器产生,输出信号通过示波器显示、采集。实验环境如图 11 所示。ECG 后级放大电路间歇故障注入位置如图 12 所示。采用频率为 1 kHz、振幅为 1 V 的正弦波作为该电路的激励信号。其中 ECG 后级放大电路不同故障状态的电路输出信号如图 13 所示。

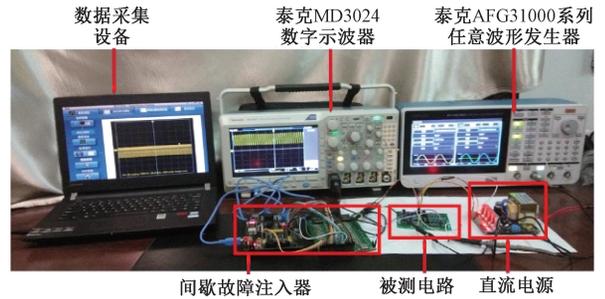


图 11 实验装置

Fig. 11 Experimental device

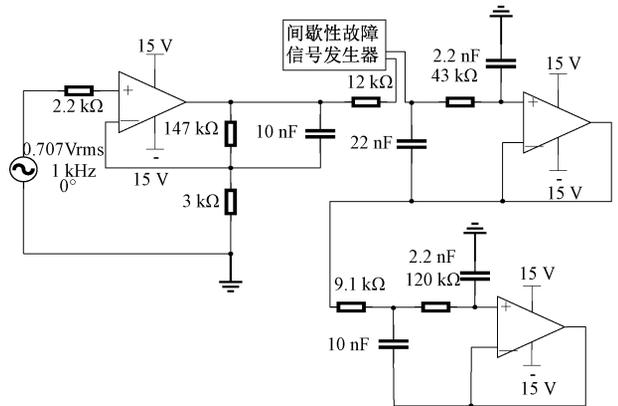


图 12 ECG 后级放大电路间歇故障注入

Fig. 12 Intermittent fault injection of ECG post-amplification circuit

表 2 故障等级划分

Table 2 Fault classification

故障等级	N_s /次	T_{safe} /ms
1	[0,1]	[41,50]
2	[2,4]	[29,35]
3	[5,8]	[25,28]
4	[9,10]	[20,23]
5	[10,12]	[15,18]
6	[13,15]	[9,12]
7	[16,18]	[4,6]
8	[19,20]	[0.5,0.8]

从被测电路中采集每种故障严重程度的样本各 100 组,总共 800 组样本。将数据集分为训练集和测试集,各含 400 个样本,其中每个严重程度 50 个样本。完成一次测试后,进行交叉验证,即交换训练集和测试集,再次训练并对新的测试样本进行识别,最后取两次测试识别准确率的平均值评估识别结果。分为 20 段,每段 200 个数据点。LSTM 网络的细胞单元隐藏层向量维度设定为 500,softmax 全连接网络层单元数量和输出的样本类别为 8,对应 8 种间歇故障严重程度。

表 3、4 分别为 LSTM 在两次交叉测试实验中对测试

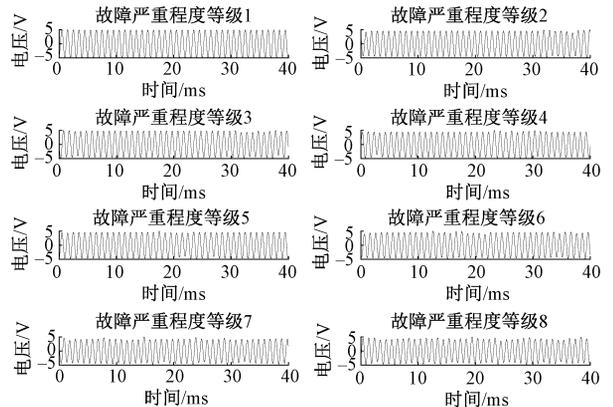


图 13 ECG 电路不同间歇故障注入下的输出波形

Fig. 13 ECG circuit output waveform under different intermittent fault injection

样本的故障识别结果,表格的纵向标签栏代表标注的故障严重程度等级,横向标签栏代表识别的故障严重程度等级(L_x 表示处于故障严重程度等级, $x=1,2,\dots,8$),表中数字代表样本的数量。

表 3 基于 LSTM 的 ECG 电路识别结果(实验 1)

Table 3 Recognition results of ECG circuit based on LSTM network (Experiment 1)

	L1	L2	L3	L4	L5	L6	L7	L8
L1	50	1	1	-	-	-	-	-
L2	-	45	1	-	-	-	-	4
L3	-	4	46	3	-	-	-	-
L4	-	-	2	46	1	-	-	-
L5	-	-	-	1	48	-	-	-
L6	-	-	-	-	-	50	-	-
L7	-	-	-	-	-	-	50	-
L8	-	-	-	-	1	-	-	46

表 4 基于 LSTM 的 ECG 电路识别结果(实验 2)

Table 4 Recognition results of ECG circuit based on LSTM network (Experiment 2)

	L1	L2	L3	L4	L5	L6	L7	L8
L1	50	1	3	-	-	-	-	-
L2	-	44	2	-	-	-	-	3
L3	-	5	45	3	-	-	-	1
L4	-	-	-	47	1	-	-	1
L5	-	-	-	-	48	1	-	-
L6	-	-	-	-	-	49	-	-
L7	-	-	-	-	-	-	50	0
L8	-	-	-	-	-	-	-	45

4.2 对比实验与结果分析

为了更好地评估 LSTM 网络的性能,利用文献[19]方法,先将样本经过小波变换(wavelet transform, WT),将3层小波分解之后的小波能量作为其特征,再采用支持向量机(support vector machine, SVM)对测试样本进行分类。同时也采用极限学习机(extreme learning machine, ELM)^[20]作为分类器对样本特征进行分类识别,并比较两种方法效果,其中 ELM 隐藏层的数量设置为 500。

1) 对比实验 1: 利用小波变换-支持向量机(WT-SVM)方法的识别结果如表 5、6 所示。

表 5 基于 WT-SVM 的 ECG 电路识别结果(实验 1)

Table 5 Recognition result of ECG circuit based on WT-SVM (Experiment 1)

	L1	L2	L3	L4	L5	L6	L7	L8
L1	50	1	5	-	-	-	-	-
L2	-	41	5	-	1	1	-	3
L3	-	4	37	2	-	1	-	1
L4	-	1	-	39	5	4	4	3
L5	-	-	-	1	40	3	3	-
L6	-	2	2	1	3	38	2	2
L7	-	1	-	7	1	1	40	4
L8	-	-	1	-	-	2	1	37

表 6 基于 WT-SVM 的 ECG 电路识别结果(实验 2)

Table 6 Recognition result of ECG circuit based on WT-SVM (Experiment 2)

	L1	L2	L3	L4	L5	L6	L7	L8
L1	50	1	3	-	-	1	-	-
L2	-	47	7	1	-	-	1	2
L3	-	2	30	1	7	-	-	1
L4	-	-	5	42	2	-	-	2
L5	-	-	-	4	38	2	-	1
L6	-	-	-	-	1	40	-	5
L7	-	-	3	-	1	2	41	7
L8	-	-	2	-	1	5	8	32

2) 对比实验 2: 利用小波变换-极限学习机(WT-ELM)方法的识别结果如表 7、8 所示。

表 7 基于 WT-ELM 的 ECG 电路识别结果(实验 1)

Table 7 Recognition result of ECG circuit based on WT-ELM (Experiment 1)

	L1	L2	L3	L4	L5	L6	L7	L8
L1	50	1	6	1	6	-	2	-
L2	-	41	2	-	2	3	1	3
L3	-	4	32	-	-	1	2	1
L4	-	1	4	44	4	-	2	3
L5	-	-	4	5	34	3	3	-
L6	-	2	1	-	3	40	2	2
L7	-	1	-	-	1	4	37	4
L8	-	-	1	-	-	1	1	37

表 8 基于 WT-ELM 的 ECG 电路识别结果(实验 2)

Table 8 Recognition result of ECG circuit based on WT-ELM (Experiment 2)

	L1	L2	L3	L4	L5	L6	L7	L8
L1	50	1	3	-	-	-	-	-
L2	-	33	-	2	2	6	1	1
L3	-	3	20	3	4	2	1	4
L4	-	-	7	37	5	4	3	2
L5	-	4	8	4	31	4	3	3
L6	-	3	6	2	1	23	6	8
L7	-	1	4	2	5	6	28	5
L8	-	5	2	-	2	5	8	27

为了对比方法对于间歇故障状态识别的性能,以识别准确率 A_c 作为评价 LSTM 性能的指标,其计算公式为:

$$A_c = \frac{N_{co}}{N_{co} + N_f} \tag{10}$$

其中, N_{co} 表示识别结果正确的样本数量, N_f 为识别结果错误的样本数量。

将每次实验中两次交叉测试实验的识别正确率取平

均值作为该实验所用方法的整体识别正确率。对比结果如表 9 所示。由表 9 可知,相比于 WT-SVM 和 WT-ELM, 本文方法对于间歇故障严重程度识别有更高的准确率。

表 9 不同方法的识别结果对比

Table 9 Comparison of recognition results of different methods

识别方法	LSTM	WT-SVM	WT-ELM
识别结果	95.25%	80.25%	65.50%

3) 方法对训练样本数量的敏感性分析

以 ECG 后期放大电路为例,使用间歇故障注入的方法生成训练样本数量分别设置为 50 组/故障严重程度、60 组/故障严重程度、70 组/故障严重程度、80 组/故障严重程度、90 组/故障严重程度、100 组/故障严重程度的训练数据,而测试样本的数量依然为 50 组/故障严重程度,分别计算方法识别准确率。得到 LSTM(本文采用的方法)、WT-SVM 和 WT-ELM 的识别率随训练样本数量的变化如图 14 所示。

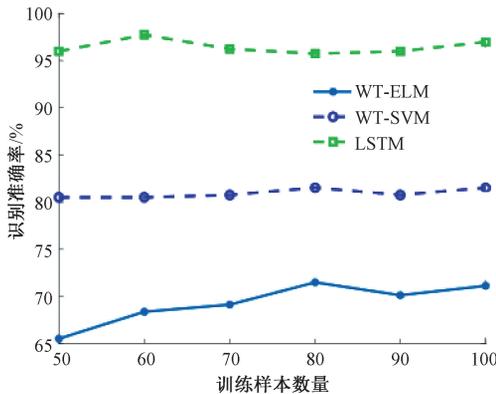


图 14 方法对样本数量的敏感性曲线

Fig. 14 Method sensitivity curve to sample size

由图 14 可知,随着训练样本数量的增加,LSTM 网络与 WT-SVM 的识别率没有明显的变化,而 WT-ELM 识别准确率有上升的趋势。并且随着样本数的增加,LSTM 网络的识别率仍然高于 WT-SVM 和 WT-ELM,该结果表明,本文方法对样本数的敏感性不高,具有更好的泛化性能。

4) 方法的鲁棒性分析

在间歇故障数据的实际采集过程中,由于设备、环境等原因不可避免地会出现数据损坏、缺失的情况。因为间歇故障的随机性,数据丢失可能会错过间歇故障发生的事件,导致严重程度识别出现偏差。因此,LSTM 网络对于含有缺失数据样本的识别能力至关重要。另一方面,当发生间歇故障的电子系统处于较为极端的环境时,导致采集到的原始数据存在一定噪声,容易导致识别结果错误。

为了模拟数据缺失的情况,在测试样本中随机删去 200~400 个连续的数据点,被删数据点在整个样本序列中的位置是随机的。同时在缺失数据的原始信号中混入均值为 0,方差等于被测电路供电电源正电压 1% 的高斯噪声作为测试样本。完整的样本与对应的混入噪声的缺失数据样本的波形对比如图 15 所示。被检测网络选择为每种故障状态 50 个,总共 400 个样本训练而成。

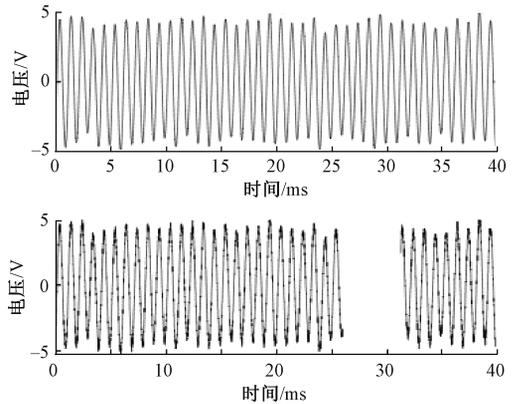


图 15 正常样本与含噪声的残缺样本对比

Fig. 15 Comparison of normal samples and incomplete samples with noise

考虑到噪声以及数据缺失的随机性,分别对测试样本进行 10 次随机处理,每次数据缺失的位置以及混合的噪声随机生成,识别结果如图 16 所示,总体识别正确率保持在 90% 左右,说明了本文方法的对缺失数据和包含噪声干扰的间歇故障数据具有良好的鲁棒性。

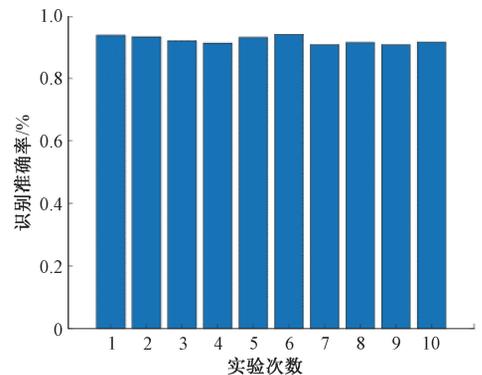


图 16 测试样本在存在环境噪声与数据缺失情况下的识别结果

Fig. 16 Recognition results of test samples in the presence of environmental noise and missing data

5 结 论

本文提出了一种基于 LSTM 网络的间歇故障严重程度识别方法,该方法可以有效识别电子系统间歇故障严

重程度,且具有良好泛化性能和鲁棒性。相比于传统的机器学习方法,本文方法无需提取故障电路输出信号的特征,利用深度学习理论,直接通过原始数据即可准确识别出系统所处的间歇故障状态。通过对比实验,证明了本文方法的有效性和可行性。本文方法可以被应用于航空航天、高速列车运输、电子医疗设备、军事装备等关乎国计民生的领域,为这些领域的电子系统间歇故障预测和健康状态管理提供技术支持。

参考文献

- [1] 吕克洪,程先哲,李华康,等. 电子设备故障预测与健康管理技术发展新动态[J]. 航空学报,2019,40(11):18-29.
- LYU K H, CHENG X ZH, LI H K, et al. New developments of prognostic and health management technology for electronic equipment [J]. Acta Aeronautica et Astronautica Sinica, 2019, 40 (11): 18-29.
- [2] JOKSIMOVIC G M, RIGER J, WOLBANK T M, et al. Stator-current spectrum signature of healthy cage rotor induction machines[J]. IEEE Transactions on Industrial Electronics, 2013, 60(9):4025-4033.
- [3] 周东华,史建涛,何潇. 动态系统间歇故障诊断技术综述[J]. 自动化学报,2014,40(2):161-171.
- ZHOU D H, SHI J T, HE X. Summary of intermittent fault diagnosis technology of dynamic system [J]. Acta Automatica Sinica,2014,40(2):161-171.
- [4] ZANARDELLI W G, STRANGAS E G, AVIYENTE S. Identification of intermittent electrical and mechanical faults in permanent-magnet ac drives based on time - frequency analysis [J]. IEEE Transactions on Industry Applications, 2017, 43(4):971-980.
- [5] CAI B, LIU Y, XIE M. A dynamic-bayesian-network-based fault diagnosis methodology considering transient and intermittent faults [J]. IEEE Transactions on Automation Science and Engineering, 2016, 14 (1): 276-285.
- [6] CAI B, LIU Y, HU J, et al. Bayesian Networks in Fault Diagnosis: Practice and Application[M]. 2019.
- [7] SINGH S, SUBRAMANIA H S, HOLLAND S W, et al. Decision forest for root cause analysis of intermittent faults [J]. IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews), 2012, 42(6):1818-1827.
- [8] 谢佳琪,尤伟,沈长青,等. 基于改进卷积深度置信网络的轴承故障诊断研究[J]. 电子测量与仪器学报,2020,34(2):36-43.
- XIE J Q, YOU W, SHEN CH Q, et al. Bearing fault diagnosis based on improved convolution deep belief network [J]. Journal of Electronic Measurement and Instrumentation, 2020,34(2):36-43.
- [9] LI H, LYU K, QIU J, et al. Application of wavelet transform in intermittent fault fearture extraction [C]. 2018 Prognostics and System Health Management Conference (PHM-Chongqing). IEEE, 2018:14-19.
- [10] ZHANG J, CHRISTOFIDES P D, HE X, et al. Intermittent sensor fault detection for stochastic LTV systems with parameter uncertainty and limited resolution [J]. International Journal of Control, 2020, 93(4):788-796.
- [11] LI Y, ZHOU X, LI S. An Intermittent fault injection strategy for electronic equipment health status recognition [C]. The 11th International Conference on Prognostics and System Health Management. Jinan, 2020:68-73.
- [12] KARIM F, MAJUMDAR S, DARABI H, et al. LSTM fully convolutional networks for time series classification [J]. IEEE Access, 2018, 6(99):1662-1669.
- [13] VURAL N M, ILHAN F, YILMAZ S F, et al. Achieving online regression performance of LSTMs with simple RNNs [J]. IEEE Transactions on Neural Networks and Learning Systems, 2021, DOI: 10.1109/TNNLS.2021.3086029.
- [14] KAREVAN Z, SUYKENS J A K. Transductive LSTM for time-series prediction: An application to weather forecasting [J]. Neural Networks, 2020, 125:1-9.
- [15] HINTON G E, SRIVASTAVA N, KRIZHEVSKY A, et al. Improving neural networks by preventing co-adaptation of feature detectors [J]. Computer Science, 2012, 3(4):212-223.
- [16] QIAN L, KEHONG L, JING Q, et al. Research on residual life prediction for electrical connectors based on intermittent failure and hidden semi-markov model [J]. Applied Sciences, 2018, 8(8):1373-1379.
- [17] SCHMIDHUBER J. Deep learning in neural networks: An overview [J]. Neural Networks, 2015, 61:85-117.
- [18] WANG X, JIANG L, CHAKRABARTY K. LSTM-based analysis of temporally- and spatially-correlated signatures for intermittent fault detection [C]. 2020 IEEE 38th VLSI Test Symposium (VTS). IEEE, 2020:1-6.
- [19] LONG B, HUANG J, TIAN S. Least squares support vector machine based analog-circuit fault diagnosis using wavelet transform as preprocessor [C]. International Conference on Communications. IEEE, 2012:1026-1029.
- [20] HUANG G B, ZHU Q Y, SIEW C K. Extreme learning

machine; Theory and applications[J]. Neurocomputing, 2014, 70(1-3): 489-501.

作者简介



李晟, 2004 年于中南大学取得学士学位, 2008 年于中南大学获得硕士学位, 2020 年于中南大学获得博士学位, 现为江西理工大学副教授, 主要研究方向为电子系统故障预测与健康管

E-mail: leeshjxust@gmail.com

Li Sheng obtained a bachelor's degree from Central South University in 2004, a master's degree from Central South University in 2008, and a doctorate degree from Central South University in 2020. He is currently an associate professor at Jiangxi University of Science and Technology. His main research interests are electronic system fault prediction and health management, complex system simulation and simulation reliability assessment.



邓江云, 江西理工大学在读研究生, 主要研究方向为电子系统故障预测与健康管

理、信号处理。
E-mail: djysz@foxmail.com

Deng Jiangyun is a M. Sc. candidate in Jiangxi University of Science and Technology.

His main research interests include electronic system fault prediction and health management, signal processing.



李玉晓(通信作者), 2005 年于大同大学取得学士学位, 2008 年于中南大学取得硕士学位, 现为江西理工大学讲师, 主要研究方向为信号与信息处理和模式识别。

E-mail: 472619115@qq.com

Li Yuxiao (Corresponding author), received a bachelor's degree from Datong University in 2005, a master's degree from Central South University in 2008, and is now a lecturer at Jiangxi University of Science and Technology. His main research interests are signal and information processing and pattern recognition.