

基于自适应窗口 LITF-LSTM 的 DC-DC 电路故障预测

张 强¹, 战柯柯²

(1. 国网安徽省电力有限公司南陵县供电公司, 安徽 芜湖 242400;

2. 国网安徽省电力有限公司繁昌县供电公司, 安徽 芜湖 241200)

摘要: 为了提高电力电子电路故障预测的准确性和快速性, 对所采用的故障特征性能参数利用 LIFT 保真去噪法进行处理, 并根据数据特征划分多个数据窗口, 利用长短记忆神经网络 LSTM 对 DC-DC 电路特征性能参数达到自适应预测。预测时可自动调整窗口的大小, 找到最优的训练集个数, 使得预测精度最高。以 DC-DC 电路中的 boost 电路为例, 以输出电压作为监测信号, 并计算特征参数 U_{pp} 和 U_{ave} 。根据电路性能设定电压阈值, 分别建立基于自适应数据窗口的 LSTM 故障预测模型和基于自适应数据窗口的 LITF-LSTM 故障预测模型, 通过对比分析预测结果, 充分说明 LITF-LSTM 预测模型的有效性, 最后分析预测数据是否达到所设阈值来判断电路在未来时刻是否发生故障。

关键词: DC-DC 电路; LSTM; LITF-LSTM; 故障预测; 自适应窗口; LIFT

中图分类号: TM769 **文献标志码:** B **文章编号:** 1001-9898(2021)02-0007-05

DC-DC Circuit Fault Prediction of LITF-LSTM Based on Adaptive Window

ZHANG Qiang¹, ZHAN Keke²

(1. State Grid Anhui Electric Power Co., Ltd. Nanling Power Supply Company, Wuhu 242400, China;

2. State Grid Anhui Electric Power Co., Ltd. Fanchang Power Supply Company, Wuhu 241200, China)

Abstract: In order to improve the accuracy and rapidity of power electronic circuit fault prediction, In this paper, the fault characteristic performance parameters used are processed according to the LIFT fidelity denoising method, and divides multiple data windows according to data characteristics, using Long Short-Term Memory (LSTM) to adaptively predict the characteristic performance parameters of DC-DC circuits. The size of the window can be adjusted automatically during prediction, finds the optimal number of training sets, makes the prediction accuracy the highest. Taking the boost circuit in the DC-DC circuit as an example, Use the output voltage as the monitoring signal, calculates the characteristic parameters U_{pp} and U_{ave} to set the voltage threshold according to the circuit performance, and establish the LSTM fault prediction model based on the adaptive data window and the LITF-LSTM fault prediction model based on the adaptive data window, By comparing and analyzing the prediction results, explains the validity of the LITF-LSTM prediction model, Finally, analyzes whether the predicted data reaches the set threshold to determine whether the circuit is malfunctioning in the future.

Key words: DC-DC circuit; LSTM; LITF-LSTM; fault prediction; adaptive window; LIFT

0 引言

电力电子电路是电源和各种驱动器的核心元件, DC-DC 电路发生故障可能使设备损坏, 导致灾难性事故发生, 严重时会造成人员伤亡。如果能准确和快速检测出要发生的故障, 就能有效解决上述问题^[1-3]。因此对故障预测技术的研究是非常重要的, 尤其是将故障预测技术应用于电力电

子电路的故障预测中。

目前, 常用的预测算法包括时间序列^[4]、神经网络^[5]支持向量机回归预测^[6]、递归神经网络 (RNN)^[7-10]。以上文献中都是对特征参数进行了简单的处理, 都未对特征参数进行去噪处理, 针对电力电子电路故障预测的特征参数多是选择电路中的关键元器件, 而电路级的故障预测则很少。

深度学习是人工智能领域的一种新方法, 在

收稿日期: 2020-07-10

作者简介: 张 强 (1990-), 男, 工程师, 主要研究电力电子与电力传动, 主要从事变电检修工作。

图像处理^[11]、文字语言相关的语言建模^[12]、医学相关的蛋白质二级结构序列预测^[13]、状态预测^[14-15]方面都取得了很大的成就,但在DC-DC电路故障预测方面研究较少,尤其是长短记忆神经网络(Long Short-Term Memory Neural Network, LSTM)解决了RNN的梯度消失和梯度爆炸的缺陷^[16-17],能够对时间序列数据进行可靠的建模,充分挖掘出了序列中隐藏的问题。因此,本文提出了一种基于LIFT-LSTM智能算法对DC-DC电路进行系统级故障预测。

1 LIFT 概述

1.1 LIFT 去噪

在电力电子电路的实时监测过程中,被监测的信号往往伴随着大量噪声。为提高预测精度,需要将特征参数中的噪声去除^[18]。本文利用LIFT保真去噪的方法,对原始数据进行去噪处理。

1.2 LSTM 介绍

长短记忆神经网络LSTM作为一种特殊的循环神经网络,利用一些特殊的设计来解决层内节点联系的问题,解决了诸多算法存在的弊端^[19-20],LSTM的原理如图1所示。




图1 LSTM的原理示意

LSTM做的改进主要是在RNN的基础上加门控机制,分别为遗忘门、输入门和输出门。

a. 遗忘门:单元中的记忆,上一时刻的值会传递到下一时刻。

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (1)$$

b. 输入门:起到控制流的作用。

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (2)$$

$$\tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C) \quad (3)$$

c. 输出门:包括记忆,输出的隐含状态,主要是输出门的作用。

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (4)$$

$$h_t = o_t \tanh(C_t) \quad (5)$$

d. 记忆更新:由两部分组成,一是遗忘门乘这一时刻的记忆,二是输入门乘这一时刻得到的新的信息。

$$C_t = f_t C_{t-1} + i_t \tilde{C}_t \quad (6)$$

在电力电子电路故障预测中,将历史数据作为输入,LSTM的作用则是在先验信息的条件下对下一个时间序列的数据进行预测。

利用历史时刻输出电压纹波值和输出电压平均值构建LIFT-LSTM预测模型,把当前时刻设定为 k 时刻,输出 $k+p$ 时刻的预测值,达到电路第 $k+p$ 时刻的工作状态的预测,LIFT-LSTM预测模型的输入、输出关系如图2所示。



图2 LIFT-LSTM预测模型输入、输出关系

$X_1, X_2, X_3, \dots, X_n$ 为不同维度的网络训练样本, $Y_1, Y_2, Y_3, \dots, Y_m$ 为不同维度训练样本下的预测输出值。

1.3 数据窗口划分介绍

数据总长度为 $m = p + nt$,构建的数据窗的长度为 p ,各窗口间的步长为 t ,数据窗的划分如下:
 $[x_1, x_2, \dots, x_p], [x_{t+1}, x_{t+2}, \dots, x_{p+t}], \dots, [x_{nt+1}, x_{nt+2}, \dots, x_{p+nt}]$

将数据窗分别输入至LIFT-LSTM预测模型中进行网络训练,输入测试集进行预测,通过RSME的值来分析预测精确度。

2 电力电子电路故障预测方法

当前深度学习是应用于模式识别和人工智能领域的一种新方法,在很多领域都得到广泛的应用,但是却很少应用于DC-DC电路的故障预测中。本文提出一种基于自适应数据窗的LIFT-LSTM的DC-DC电路故障预测方法,对自适应数据窗利用LIFT-LSTM预测特征参数,根据数据的特点对自适应数据窗进行预测时寻找到最优的训练集,不仅节约了预测时间,更是使得预测精度得到提升。

2.1 预测方法步骤总体叙述

LIFT-LSTM对电力电子电路故障预测的实现过程如图3所示,具体步骤为。

a. 设置仿真电路利用saber仿真软件进行DC-DC电路仿真,设置本次实验的仿真时间为30ms,仿真步长为 $1 \mu s$ 。

b. 选择输出电压信号 v_{out} 、输入电流信号 i_i




图3 基于LIFT-LSTM的DC-DC电路故障预测框图和输出电流信号 i_o 与MOSFET各参数值进行监测,获得被监测信号的波形以及数据,然后重复此过程,共采集1500个参数数据。

c. 对所监测信号进行数据处理,计算其纹波电压、平均电压作为故障预测特征参数,并对其特征参数进行LIFT保真去噪处理,根据数据特点划分若干数据窗。

d. 对数据窗利用LIFT-LSTM对特征参数进行预测,根据数据的特点对数据窗自适应进行预测时寻找到最优的训练集个数,从而调整数据窗的大小,达到最优的预测;对其他段数据的预测则重复以上步骤。

e. 对预测数据进行分析,判断此刻是否故障。

2.2 数据来源

利用saber仿真软件搭建的DC-DC开关功率变换器仿真电路如图4所示。

根据电力电子电路的特点可知,在电路刚开始运行时,输出电压会增长较快,后趋于平稳,为了保证数据的可靠性,本文所采用的特征参数均是当电路达到稳定后的值,由公式(7)、(8)计算出用于预测的特征参数,即平均电压和纹波电压,其变化趋势如图5和图6所示。

输出电压平均值计算公式:

$$U_o = \frac{1}{N} \sum_{k=1}^N V_{out}(t) \quad (7)$$




图4 DC-DC开关功率变换器电路原理




图5 U_{ave} 值的变化情况
纹波电压的变化关系如图6所示。




图6 U_{pp} 值的变化情况

输出纹波电压计算公式:

$$U_{pp} = V_{out}(\max) - V_{out}(\min) \quad (8)$$

2.3 评判标准

2.3.1 预测评判标准

基于时间序列数据的LIFT-LSTM预测模型的预测效果,主要可以通过均方根误差RMSE进行评估,其公式如式(9):

$$RMSE = \sqrt{\sum_{t=1}^N (x'_t - x_t)^2 / N} \quad (9)$$

式中: x'_t 为 t 时刻纹波电压与平均电压的预测值; x_t 为 t 时刻的纹波电压的实测值; N 为所预测数据的个数。均方根误差RMSE:预测值与实测值偏差的平方和观测系数比值的平方根,用以说明预测准确程度,其值越小越好。

2.3.2 故障评判标准

在DC-DC电路退化仿真实验中,其输入为12 V的直流电压,输出为24 V的直流电压。由DC-DC电路的性能指标要求,输出电压纹波噪声小于输出电压的1%,所以设定故障参数阈值为0.24 V。通过判断预测 U_{pp} 是否大于0.24 V,进而判断DC-DC开关功率变换器是否发生了故障,电路正常工作时平均电压 U_{ave} 的值为23.96 V,根据DC-DC电路的性能指标的要求,输出电压平均值超出正常工作时的平均电压的 $\pm 2\%$ 时,电路不再满足负荷的需要,则判定当前时刻为故障,需停机检修。

3 LIFT-LSTM 预测结果分析

为了验证LIFT-LSTM能够利用数据窗对DC-DC电路级特征参数进行自适应的迭代预测,使得预测更加精确和快速,且能够根据数据特点找到最优的训练集个数,得到很高的预测精度,使得预测时间缩短,经过大量的实验经验来设置LIFT-LSTM预测模型的学习率、迭代次数、学习降低率以及设置隐藏层数。

以boost电路输出电压作为监测信号,经过数据处理得到时间序列数据纹波电压和平均电压,利用LIFT-LSTM预测模型和LSTM预测模型对数据窗进行预测。通过分析RMSE来判断其预测精度。

经过实验验证了数据窗的长度为100,数据窗的间隔为20,每次预测最新的20个数据,可根据上述步骤依次对相同步长的未来数据进行预测,可以使预测精度大大提升。

根据数据特征对自适应窗进行预测,寻找到使得预测精度最高的训练集个数,样本可随机选取。为验证方法的可行性,本文采用的是预测第1 240—1 260这20个时刻点数据为例,当对此数据窗利用LSTM预测模型和LIFT-LSTM预测模型进行预测,结果如表1所示。

由表1可知,利用LSTM预测模型分别对 U_{pp} 、 U_{ave} 进行预测,其结果为:纹波电压当训练集为70时预测效果最好,平均电压当训练集为75时预测效果最好,且由表1可知,并不是训练集个数越多预测效果更高。利用LIFT-LSTM预测模型分别对 U_{pp} 、 U_{ave} 进行预测,其结果为:纹波电压当训练集为80时预测精度最高,平均电压当训练集为75时预测精度最高。但当换为另一组数据窗

表1 基于LSTM、LIFT-LSTM对 U_{ave} 和 U_{pp} 的预测结果

训练集 个数	预测 步数	LSTM		LIFT-LSTM	
		U_{pp}	U_{ave}	U_{pp}	U_{ave}
		RMSE	RMSE	RMSE	RMSE
80	20	2.60×10^{-3}	7.32×10^{-4}	4.97×10^{-5}	4.81×10^{-5}
75	20	2.62×10^{-3}	7.18×10^{-4}	7.85×10^{-4}	8.26×10^{-6}
70	20	1.98×10^{-3}	1.20×10^{-3}	8.69×10^{-4}	3.66×10^{-4}
65	20	3.10×10^{-3}	9.12×10^{-4}	1.20×10^{-3}	5.94×10^{-4}
60	20	3.12×10^{-3}	1.20×10^{-3}	1.50×10^{-3}	1.45×10^{-4}
55	20	2.70×10^{-3}	9.91×10^{-4}	1.90×10^{-3}	3.57×10^{-4}
50	20	2.10×10^{-3}	1.30×10^{-3}	4.22×10^{-4}	1.08×10^{-4}
45	20	3.20×10^{-3}	8.23×10^{-4}	2.53×10^{-4}	2.60×10^{-4}
40	20	2.00×10^{-3}	1.20×10^{-3}	1.76×10^{-4}	3.25×10^{-6}
35	20	2.30×10^{-3}	9.97×10^{-4}	6.98×10^{-4}	2.32×10^{-4}
30	20	3.10×10^{-3}	8.35×10^{-4}	2.80×10^{-3}	3.21×10^{-4}

时,将数据输入至LSTM预测模型和LIFT-LSTM预测模型中,仍会自适应的自动筛选出使得RMSE最小的训练集个数,使得预测精度达到最高。预测结果如图7—12所示。




图7 平均电压去噪后的数据趋势




图8 纹波电压去噪后数据趋势




图9 LSTM预测模型对平均电压预测结果




图 10 LIFT-LSTM 对平均电压预测结果




图 11 LSTM 预测模型对纹波电压预测结果




图 12 LTFT-LSTM 预测模型对纹波电压预测结果

由以上各图预测结果可知,利用均方根误差作为评判标准,当利用 LSTM 预测模型对 DC-DC 电路进行自适应预测时,平均电压预测精度达到 7.183×10^{-4} ,纹波电压预测精度达到了 1.985×10^{-3} 。利用 LIFT-LSTM 预测模型时,平均电压预测精度达到 8.255×10^{-6} ,纹波电压预测精度达到 4.947×10^{-5} 。对比分析说明 LIFT-LSTM 预测模型的有效性,可对电路未来状态进行有效预测。

4 结论

本文研究了电力电子电路故障预测技术,将电力电子电路级故障特征性能参数与 LIFT-LSTM 相结合达到自适应的预测,预测时对训练集的个数进行寻优,使得预测时间缩短、预测精度更高。文中用到 LSTM 预测模型以及 LIFT-LSTM 预测模型,通过分析预测结果可知:LSTM

预测模型预测精度已算合格,但仍有提高的空间,因此本文对其优化,利用 LIFT-LSTM 预测模型,通过分析可知 LIFT-LSTM 预测模型的预测精度在 LSTM 预测模型基础上得到了提高,验证了 LIFT-LSTM 预测模型的有效性。文中虽然只对 boost 电路进行了实验验证,但所提的预测思想能够推广应用于其他电力电子电路中,其关键在于确定各个不同电路的故障特征参数,以及根据数据特点对其进行数据窗口的划分,此方法预测精度高,具有很好的应用前景,且使用方便。

参考文献:

- [1] SHANG Chao, YANG Fan, HUANG Dexian, et al. Data-driven soft sensor development based on deep learning technique[J]. Journal of Process Control, 2014, 24 (3): 223 - 33.
- [2] ZHOU Funa, PARK Ju H, LIU Yajuan. Differential feature based hierarchical PCA fault detection method for dynamic fault [J]. Neurocomputing, 2016, 20(2): 27 - 35.
- [3] 庞 荣,余志斌,熊维毅,等.基于深度学习的高速列车转向架故障识别[J].铁道科学与工程学报,2015,12(6):1283 - 1288.
- [4] 丛林虎,徐廷学,王 骞,等.基于退化数据与故障数据的导弹竞争故障预测[J].北京航空航天大学学报,2016,42(3): 522 - 531.
- [5] 杜 涛,阮爱武,汪 鹏,等.一种基于 BP 神经网络的集成电路 PHM 模型[J].计算机工程与科学,2017,39(1):55 - 60.
- [6] 袁义生,钟青峰.基于支持向量机的电力电子电路损耗预测[J].华东交通大学学报,2017,34(4):122 - 128.
- [7] 范竣翔,李 琦,朱亚杰,等.基于 RNN 的空气污染时空预报模型研究[J].测绘科学,2017,42(7):76 - 83.
- [8] Chung J, Kastner K, Dinh L, et al. A Recurrent Latent variable Model for Sequential Data[J]. Computer Science, 2015, 5 (8): 1340 - 1353.
- [9] 姜媛媛,王友仁,罗 慧,等.电力电子电路故障评估新指标及基于 LSSVM 的预测新方法[J].电工技术学报,2012,12 (27): 43 - 55.
- [10] Kadri, F., Drid, S., Djeflal, F., Chrifi-Alaoui, L. Neural classification method in fault detection and diagnosis for voltage Source inverter in variable speed drive with induction motor[C]. in Proc EVER 2013: 1 - 5, 27 - 30.
- [11] 刘 飞,张俊然,杨 豪.基于深度学习的医学图像识别研究进展[J].中国生物医学工程学报,2018,37(1):86 - 94.
- [12] 刘飞龙,郝文宁,陈 刚,等.基于双线性函数注意力 Bi-LSTM 模型的机器阅读理解[J].计算机科学,2017,44 (s1): 92 - 96.
- [13] 曹成远,吕 强.使用双向 LSTM 的深度神经网络蛋白质残基相互作用[J].小型微型计算机系统,2017,38(3):531 - 535.
- [14] 吴 魁,孙 洁,蒋 波,等.基于 LSTM 风洞设备健康状态评估方法研究[J].计算机测量与控制, (下转第 28 页)

搭建好神经网络仿真结构图后,需要对其进行多次训练。如图 5 所示,当电力设备系统正常运行时得到稀疏曲线,并将其作为设备正常运行的标准参考曲线,然后对新接收的数据进行分析与处理并进行仿真,将仿真得到的新波形与原有标准波形进行对比,如果波形相差在规定范围之外,则波形标注为密集曲线,然后判断电力设备是否出现故障或是否存在故障隐患。通过图 5 的波形对比可以看出该系统对波形反应精准,即使有超过规定范围较小的数据变化,该神经网络也可以识别判断。




图 5 神经网络的 MATLAB 仿真波形

神经网络的 MATLAB 仿真均方误差曲线如图 6 所示,可以看出神经网络训练结果,在神经网络训练初期误差出现了一次较大幅度的减少,然后进入了训练的平缓期,在经过累计 500~600 次的训练后,误差出现了大幅度的减少,最后在训练次数超过 700 次时,误差下降到了 10^{-3} ,达到了预期的目标。图 6 可以说明改进后的神经网络算法达到了预期的效果,这种方法是可行的。

4 结论

a. 基于改进 BP 神经网络算法建立的变压器性能参数诊断模型,可以快速准确的获取变压器




图 6 神经网络的 MATLAB 仿真均方误差曲线的运行状态,实现对变压器的故障检测。

b. 通过优化隐层节点数目来优化神经网络的结构,并且通过附加参数法修正神经网络的权值,使神经网络收敛的速度提升并且可以有效避免陷入局部最小值的问题。通过仿真实验结果可以看出,变压器故障诊断的精度和速度都达到了预期的效果。

c. 以建立变压器故障诊断模型为例,说明了人工智能技术在电力设备故障诊断上的应用,由于 BP 神经网络算法使用性高,因此可以扩展到其他电力设备的故障诊断上,为以后的研究指明了方向。

参考文献:

- [1] 唐文虎,牛哲文,赵柏宁,等.数据驱动的人工智能技术在电力设备状态分析中的研究与应用[J].高电压技术,2020,46(9):2985-2999.
- [2] 李进,张萌.基于多传感器信息融合的电力设备故障诊断方法[J].电子世界,2016(22):131,140.
- [3] 王海峰,陆军.复杂电力设备突发故障诊断方法研究与仿真[J].计算机仿真,2013,30(3):127-129,284.
- [4] 谢春丽,夏虹,刘永阔,等.BP神经网络改进算法在核电设备故障诊断中的应用[J].核动力工程,2007(4):85-90.
- [5] 余勇,万德钧,程启明.电力设备基于小波神经网络故障检测方法的仿真研究[J].盐城工学院学报,2000(2):5-9.

本文责任编辑:秦明娟

(上接第 11 页)

2018,26(3):288-291.

- [15] 代杰杰,宋辉,盛戈峰,等.采用 LSTM 网络的电力变压器运行状态预测方法研究[J].高电压技术,2018,44(4):1099-1106.
- [16] 王鑫,吴际,刘超,等.基于 LSTM 循环神经网络的故障时间序列预测[J].北京航空航天大学学报,2017,44(4):772-784.
- [17] 包晓安,常浩浩,徐海,等.基于 LSTM 的智能家居机器

学习系统预测模型研究[J].浙江理工大学学报(自然科学版),2018,39(2):224-231.

- [18] 刘柱揆,丁心志,陈福明,等.小波去噪方法在开关柜故障检测中的应用[J].电网技术,2017,41(9):3090-3094.
- [19] 赵建鹏,周俊.基于长短时记忆网络的旋转机械状态预测研究[J].噪声与振动控制,2017,37(4):155-159.
- [20] 陆凯韬,董红召,陈宁,等.基于 LSTM 的公共自行车服务点租还需求量预测[J].计算机测量与控制,2017,25(9):178-181.

本文责任编辑:丁力