

基于神经网络的支撑电容在线监测技术研究

郭燕辉¹, 李好², 罗敏², 陈杰²

(1. 北京市地铁运营有限公司运营四分公司, 北京 100035;

2. 北京交通大学 电气工程学院, 北京 100091)

摘要:在电力电子器件中,支撑电容是非常重要的部件。为了确保系统的安全性,对电容的状态监测显得尤为重要。采用神经网络的方法,通过对控制策略和电路拓扑结构参数的相关性进行分析,确定了神经网络的两个输入变量和一个输出变量,再通过BP神经网络进行训练,并将训练模型导入Simulink仿真软件,以验证理论的正确性和监测结果的准确性,最后通过搭建实验平台进行实验,验证了该方案的正确性。研究结果表明:与以往的方案相比,所提方案可以在不增加系统复杂度的情况下能够实现电容容值的在线监测。

关键词:状态监测;神经网络;支撑电容;整流变换器

中图分类号:TP277 **文献标识码:**A **DOI:**10.19457/j.1001-2095.dqed25705

Research on Online Monitoring of Support Capacitors Based on Neural Networks

GUO Yanhui¹, LI Hao², LUO Min², CHEN Jie²

(1. Fourth Operation Branch of Beijing Metro Operation Co., Ltd., Beijing 100035, China;

2. School of Electrical Engineering, Beijing Jiaotong University, Beijing 100091, China)

Abstract: In power electronic devices, the supporting capacitor is a crucial component. To ensure the safety of the system, monitoring the status of the capacitor is particularly important. A neural network approach was employed, and analyzing the correlation between control strategies and circuit topology parameters to determine two input variables and one output variable for the neural network. Subsequently, the training was conducted using a BP neural network, and the trained model was imported into Simulink simulation software to validate the correctness of the theory and the accuracy of the monitoring results. Finally, experiments were carried out using a experimental platform to verify the feasibility of the proposed solution. The research results indicate that compared to previous approaches, the proposed solution can achieve online monitoring of capacitor capacitance without increasing system complexity.

Key words: condition monitoring; neural networks; support capacitor; rectifier converter

状态监测是一种评估电力电子器件健康状况的重要方法,尤其在安全性要求较高的系统中被广泛应用,比如风机、航空航天、电动汽车等,而在这些应用场景中,变换器是系统的核心部分,变换器的失效将导致系统无法正常运行甚至于崩溃。

电容以其平滑电压及滤波等特性被广泛应用于变流系统中。若系统中有电容损坏,可能会导致变流器损坏,进而导致整个系统崩溃。特别是在机车变流器中电容损坏时有发生^[1],因此对

电容进行容值监测,及时替换容值达到失效值的电容对保障系统安全性显得尤为关键。

目前,国内外对于电容的状态监测已做了大量工作,美国奥本大学研究者建立了电容的经典模型和多支路等效电路模型用于研究电容的充放电性能。加利福尼亚大学研究者分别通过恒流放电法和恒功率放电法对电容进行测量^[2]。国内虽然起步较晚,但发展迅速,文献[3]在此方法的基础上提出了改良的测试方法,准确性较原方法最多可提升10.9%。在此方法中较小的噪声干

基金项目:北京地铁项目(E23L00710)

作者简介:郭燕辉(1987—),男,博士在读,高级工程师,主要研究方向为城市轨道交通车辆智能运维,Email:15801029096@139.com

通讯作者:陈杰(1986—),男,博士,副教授,主要研究方向为电力电子与电力传动,Email:jiechen@bjtu.edu.cn

扰将会引起较大的误差,因此对数据进行滤波处理可将误差更进一步降低^[4]。这种通过建立模型进行充放电的方法虽然精度很高,但需要将电容拆卸,并且经过完全的充放电才能够得到电容状态。在某些场景下系统不允许停机或者支撑电容不方便拆卸时,此方法便不能使用。

为了实现对电容的不停机监测,文献[5]提出了一种电流注入法来监测电容值,在中低频电路中,经由外部电路给变换器注入一个低频的电流,测量电容纹波电压和电流等信息来计算电容值以及等效串联电阻值。与此相似的,文献[6]通过注入交流电压对电容进行监测。但从外部注入电压或电流的方法均需要额外的硬件以及控制,且会对整个电路产生干扰,所应用的条件有所限制。

随着计算机技术的不断发展,深度学习的方法在各行各业均有应用。文献[7]利用现有接线形式和已有传感设备及检测信号,实现了对电力电容器的在线监测;文献[8]通过数理统计与多项式回归的算法构建电容模型来实现对电容的在线监测;文献[9]通过对数据提取特征值,经BP神经网络进行训练实现电容容值测量。以上方法虽一定程度上可以实现对电容的监测,但其物理意义不清晰,电容容值与电路拓扑中电气量的相关性不明确。

为了弥补以上方法的不足,本文参考文献[10]的分析方法对常见整流拓扑及控制策略SVPWM进行分析。并以此为基础提出一种基于神经网络的在线电容状态监测方法,并搭建仿真和实验平台验证其有效性。

1 参数相关性分析

本文提出的电容容值监测方案是,将现有可采集到的电气量输入到已训练好的神经网络中,计算得到电容容值。对于神经网络而言,其训练效果直接取决于输入变量与输出变量之间的相关度,因此本节的主要目的是分析电容容值与电路中各电气量的相关性,选取合适的电气量进行神经网络的训练。

三相整流变换器被广泛应用于实际工程之中,图1是变换器的典型拓扑结构图。其中,交流侧三相电流分别为 I_a, I_b, I_c ;直流侧输入电流为 I_{in} ,电容电流为 I_c ,直流输出侧电流为 I_o 。

对于三相整流变换器,三相桥臂上、下共有6

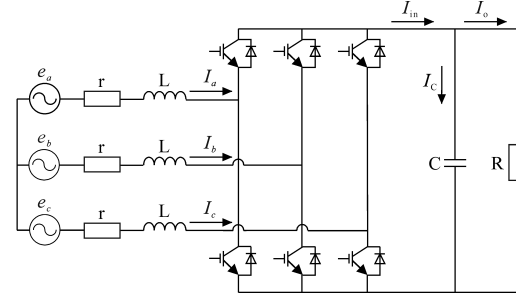


图1 三相整流拓扑图

Fig.1 Three-phase rectifier topology diagram

个开关管,且上、下桥臂的开关管为互补状态,即在某个时刻有且仅有一个桥臂导通。定义开关函数 $S_x(x=a,b,c)$:

$$S_x = \begin{cases} 1 & \text{上桥臂导通} \\ 0 & \text{下桥臂导通} \end{cases} \quad (1)$$

其直流侧电流 I_{in} 可以通过开关函数来表示:

$$I_{in} = i_a S_a + i_b S_b + i_c S_c \quad (2)$$

假设直流侧的电容容值足够大,整流器的输出电流可以被分为两个部分:一部分是流经负载的恒定直流输出电流 I_o ;另一部分是直流侧支撑电容上的纹波电流 I_c ,此纹波电流是由开关器件的高频动作所产生。负载电流和支撑电容上的纹波电流由下式表示:

$$I_o = \frac{1}{T_s} \int_0^{T_s} I_{in} dt \quad (3)$$

$$I_c = I_{in} - I_o \quad (4)$$

式中: T_s 为开关周期。

依据流经直流侧支撑电容的电流,直流侧的电压也将分为两个部分。直流侧的电压 v_o 可以由其上的平均电压 V_o 以及直流侧纹波电压 Δv_o 表示,其关系如下式所示:

$$v_o = V_o + \Delta v_o \quad (5)$$

$$\Delta v_o = \frac{1}{C} \int_0^{T_s} I_c dt = \frac{1}{C} \int_0^{T_s} (I_{in} - I_o) dt \quad (6)$$

在稳态下,一个周期之内电容两端电压不变。纹波电压最大脉动值 ΔV_o 如下式所示:

$$\Delta V_o = \max \{ \Delta v_o \} \quad (7)$$

对于如图1所示的三相整流变换器,常用的调制策略为SVPWM调制。在某一次开关矢量合成中,其开关动作及由此开关动作所得整流侧输出电流 I_{in} 波形如图2所示。

对电容而言,有:

$$i = C \frac{du}{dt} \quad (8)$$

由此关系以及流经电容的电流可得到SVPWM开关动作产生的电压波形如图3所示。




图2 SVPWM某次开关动作产生的电流波形

Fig.2 The current waveform generated by a certain switching action of SVPWM




图3 SVPWM某次开关动作产生的电压波形

Fig.3 The voltage waveform generated by a certain switching action of SVPWM

当负载变大,也就是负载电流 I_o 变大时,对应的开关管开通关断时间将会发生变化,使得 ΔV_o 发生变化。因此选取负载电流 I_o 作为神经网络的第一个输入数据。

由图3可知电容两端电压在一个开关周期内经历了两次波动,电压在开关频率的二倍频处将会有较为明显的谐波分量,此谐波分量与电容容值大小之间也有式(6)的关系。因此该谐波电压与支撑电容的大小相关性较强,选取其作为神经网络的另一个输入数据。

2 神经网络

通过理论分析可以知道,电容的容值与负载电流、直流侧开关频率2倍的谐波电压有关。本质是二输入、一输出的拟合问题,选择适合用于解决这类问题的BP神经网络进行训练。

对于BP神经网络而言,一般有三层,分别是输入层、隐藏层和输出层。无论是输入层、隐藏层还是输出层,所包含神经元的个数均可以由用户自定义,其中输入、输出层的神经元个数代表着输入、输出数据的个数。隐藏层的层数以及每层神经元个数将会影响神经网络的训练结果。

在本文中,输入数据分别为负载电流有效值以及直流侧开关二倍频的谐波电压。输出数据为电容的电容值。选择两层BP神经网络,其中隐藏层有10个神经元,激活函数采用Tansig函数,输出层有1个神经元,激活函数采用线性函数。其整体的结构如图4所示。




图4 神经网络拓扑结构图

Fig.4 Neural network topology diagram

通过实验及仿真采集到的原始数据需要经过处理才可以进行神经网络的训练,具体流程如图5所示。




图5 数据处理图

Fig.5 Data processing diagram

在输入数据与输出数据之间关联性明显时,贝叶斯正则化法与Levenberg-Marquardt法训练效果相当,而当输入数据与输出数据之间关联性不太明显时,贝叶斯正则化法训练出来的效果更好。在这里使用泛化能力强的贝叶斯正则化法进行训练。

评价训练好的神经网络模型方法有多种,本文采用回归值 R 和均方误差(mean squared error, MSE)进行评判。回归值 R 代表经神经网络预测出的输出值与目标输出之间的相关性。 R 值越接近1,表示预测数据和实际数据之间的关系越紧密, R 值越接近0,表示预测数据和实际数据之间的关系随机性越大。均方误差代表预测数据和实际数据之间的误差,可以由下式表示:

$$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2 \quad (9)$$

在确定了输入、输出数据类型、神经网络训练方法、评价网络性能的指标后。将数据导入到Matlab中进行训练。训练出的神经网络均方误差如图6所示,训练出的神经网络 R 值如图7所示。可以看出,训练后的神经网络MSE值为0.677 6,






图6 神经网络训练均方误差图


Fig.6 Neural network training MSE graph



(a)训练集 R 值图



(b)测试集 R 值图



(c)全集 R 值图

图7 神经网络训练 R -value 图

Fig.7 Neural network training R -value graph

R 值在测试集上也达到了 0.999 4。说明该模型具有很好的泛化能力,具备很高的预测精度。图 7 中, $Y=T$ 是指实际值和预测值之间的关系,如果其关系接近于一条直线,则说明回归模型的预测

效果好,反之,则说明回归模型的预测效果差,可以通过观察 $Y=T$ 的关系直观地评估回归模型的预测效果。

3 仿真分析

根据现有拓扑结构条件,在三相整流中开展仿真,其主电路拓扑结构见图 1。仿真的具体参数为:开关频率 1 000 Hz,直流侧电压 150 V,支撑电容 1 900~2 700 μF ,负载功率 360~900 W。

改变负载功率大小以及直流侧电容容值大小,对应的直流侧纹波电压变化如图 8 所示。当电容容值不变、负载增大时,电容两端纹波电压将会增大。当负载大小不变、电容增大时,电容两端纹波电压将会减小。仿真结果与理论分析所得结论一致。




图8 不同功率与容值条件下电压纹波图

Fig.8 Voltage ripple diagram under different power and capacitance conditions

对直流侧电压进行傅里叶变换后可得其在开关频率 2 倍的谐波电压幅值较为明显,是谐波电压的主要组成成分,如图 9 所示。仿真结果与理论分析所得结论一致。




图9 直流侧电压仿真波形

Fig.9 DC side voltage simulation waveforms

在仿真中改变负载大小及电容容值进行如图5所示的数据采集与处理。训练集采用电容容值变化范围为 $2\,200\sim 2\,700\ \mu\text{F}$,变化步长为 $100\ \mu\text{F}$ 。功率等级为 $360\ \text{W}$, $450\ \text{W}$, $600\ \text{W}$, $900\ \text{W}$ 下的数据。考虑到在实际中电容容值随着时间的变化将会减小,因此测试集采用电容容值变化范围为 $1\,900\sim 2\,700\ \mu\text{F}$,变化步长为 $200\ \mu\text{F}$ 。功率等级为 $375\ \text{W}$, $562.5\ \text{W}$, $750\ \text{W}$ 下的数据,预测误差如图10所示。




图10 不同功率与容值条件下神经网络预测误差图

Fig.10 Neural network prediction error diagram under different power and capacitance conditions

在实际中一般认为电容容值下降20%时电容就不能正常使用,对 $2\,200\ \mu\text{F}$ 的电容而言、其下降20%的容值为 $1\,760\ \mu\text{F}$,考虑到系统安全性,将本次电容容值预测的边界值设置成 $1\,900\ \mu\text{F}$ 。由图10可知,本文所提出的方法在不同功率等级下均可实现电容的预测。其预测误差最大为4.132%。在实际应用中有着较高的可行性。

4 实验分析

实验电路与仿真电路相似,采用整流拓扑进行实验,其参数与仿真参数相同。实验采用DSP+FPGA的控制方式。FPGA接入电压、电流传感器,负责对采集到的数据以图5的方式进行处理。对电压在 $2\,000\ \text{Hz}$ 处纹波的提取以及对电流有效值的求取均在FPGA中完成。DSP负责接收FPGA处理好的数据,经过训练好的神经网络计算出实时的电容容值,并通过通信接口传输给上位机。其控制架构如图11所示,实验台照片如图12所示。

通过上述方法利用采集到的数据进行神经网络的训练,训练集采用的电容容值为 $2\,400\ \mu\text{F}$, $2\,500\ \mu\text{F}$, $2\,600\ \mu\text{F}$ 、功率等级为 $600\ \text{W}$, $294\ \text{W}$ 下的数据。测试集采用电容容值为 $2\,200\ \mu\text{F}$, $2\,300\ \mu\text{F}$ 、功率等级为 $600\ \text{W}$, $294\ \text{W}$ 下的数据。

对实验采集到的直流侧电压进行傅里叶变换,可得其在开关频率2倍的谐波电压幅值较为

明显,是谐波电压的主要组成成分,如图13所示。实验结果与理论分析所得结论一致。

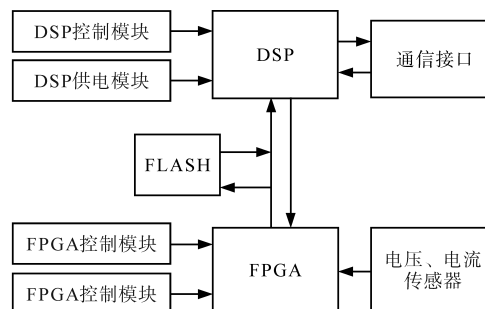


图11 实验电路系统架构

Fig.11 System architecture of experimental circuit




图12 实验平台

Fig.12 Experimental Platform




图13 直流侧电压实验波形

Fig.13 DC side voltage experimental waveforms

通过两组测试数据进行电容值预测,其预测结果及误差如表1所示。

表1中记录了不同功率等级和不同电容容值时通过神经网络训练得到的电容容值结果,计算误差最大为3.907%,此误差受硬件电路、实验环境等因素的影响,整体趋势为高电容容值条件下误差略小于低电容容值条件下的误差,低功率条

表 1 实验数据下神经网络预测误差

Tab.1 Neural network prediction error under experimental data

实际电容/ μF	神经网络输出电容/ μF	误差/%	功率等级/W
2 300	2 321.14	0.919	600
2 200	2 285.95	3.907	600
2 300	2 270.82	1.268 7	294
2 200	2 180.55	0.884 1	294

件下的误差略小于高功率条件下的误差。在此基础上还受神经网络训练时带来的随机性影响,误差总体为在一定规律下的随机分布,但总体变化不大,满足实际工程中精度需要。实验结果说明了本文所提方法的可行性,能够较为准确地实现电容容值的在线监测。

5 结论

本文通过分析变换器的拓扑结构及其常见的 SVPWM 控制方式确定了与电容容值相关的电气量,并将其作为神经网络的输入变量。随后进行神经网络的训练,开展仿真并进行实验。通过分析仿真及实验结果可以得到:提出的方法可以在不增加额外设备的条件下实现对电容的在线监测,实验中电容预测误差最大为 3.907%,在实际应用中可行性较高。

参考文献

- [1] 童克锋. 机车变流器直流及滤波电容器的失效原因与抑制措施研究[J]. 铁道机车与动车, 2016(2): 27-30, 48.
TONG Kefeng. Failure cause and countermeasures of DC and filter capacitor in locomotive converter[J]. Railway Locomotive and Motor Car, 2016 (2): 27-30, 48.
- [2] 秦怡. 超级电容器静电容量和内阻测试方法的研究[D]. 上海: 上海交通大学, 2017.
QIN Yi. Research on measurement method of capacitance and equivalent series resistance of supercapacitor[D]. Shanghai: Shanghai Jiao Tong University, 2017.
- [3] 郭航. 超级电容静电容量和等效串联内阻测试方法研究及

优化[D]. 杭州: 浙江大学, 2021.

- GUO Hang. Research and optimization of measurement method for electrostatic capacity and equivalent series internal resistance of super capacitors[D]. Hangzhou: Zhejiang University, 2021.
- [4] 潘浩, 尹相辉, 伦秀春, 等. 基于扩展卡尔曼滤波的超级电容容值测量[J]. 电源技术, 2023, 47(7): 940-944.
PAN Hao, YING Xianghui, LUN Xiuchun, et al. Supercapacitor capacitance measurement based on extended Kalman filter [J]. Chinese Journal of Power Sources, 2023, 47(7): 940-944.
- [5] PU X, NGUYEN T H, LEE D, et al. Fault diagnosis of DC-link capacitors in three-phase AC/DC PWM converters by online estimation of equivalent series resistance[J]. IEEE Transactions on Industrial Electronics, 2013, 60(9): 4118-4127.
- [6] ABO-KHALIL A G, LEE D. DC-link capacitance estimation in AC/DC/AC PWM converters using voltage injection[J]. IEEE Transactions on Industry Applications, 2008, 44 (5) : 1631-1637.
- [7] 梁东. 电力电容器在线监测关键技术研究及应用[D]. 淄博: 山东理工大学, 2020.
LIANG Dong. Research and application of key technologies for online monitoring of power capacitors[D]. Zibo: Shandong University of Technology, 2020.
- [8] 侯飞, 张金城, 刘强, 等. 牵引系统支撑电容 PHM 技术研究[J]. 电子测量技术, 2021, 44(2): 132-136.
HOU Fei, ZHANG Jincheng, LIU Qiang, et al. Research on PHM technology of traction system support capacitor[J]. Electronic Measurement Technology, 2021, 44(2): 132-136.
- [9] 刘湘鹏, 袁冠辉, 陆永辉, 等. 基于 BP 神经网络的高精度电容测量[J]. 无线电工程, 2022, 52(3): 399-406.
LIU Xiangpeng, YUAN Guanhui, LU Yonghui, et al. A high-precision capacitance measurement method based on BP neural network[J]. Radio Engineering, 2022, 52(3): 399-406.
- [10] LEE J, KIM M W, KIM I, et al. Analysis of DC-link voltage ripple by generalized discontinuous pwm strategy in two-level three-phase voltage source inverters[C]//2022 IEEE/AIAA Transportation Electrification Conference and Electric Aircraft Technologies Symposium (ITEC+EATS), 2022: 49-54.

收稿日期: 2024-03-18

修改稿日期: 2024-05-10