

DOI: 10.19344/j.cnki.issn1671-5276.2019.06.042

基于ACGAN的功率变换器参数性故障诊断方法

傅宏辉,王友仁,孙灿飞,孙权

(南京航空航天大学 自动化学院,江苏 南京 211106)

摘要:提出了一种基于辅助分类生成对抗网络的功率变换器参数性故障智能诊断方法。首先采集功率变换器的测点电压与支路电流信号,提取信号的时域特征,构成故障特征向量。采用对抗学习机制训练生成器和判别器,由ACGAN中生成器构造与真实故障特征分布近似的伪数据,从而将伪数据与真实数据同时用于训练判别器,判别器通过判别真伪数据来训练生成器。以Buck变换器为例,验证了所提出的故障诊断方法的可行性,结果表明ACGAN故障诊断方法相对于传统神经网络具有更高的故障诊断率与更优的泛化性能。

关键词:故障诊断;对抗学习机制;功率变换器;深度学习;ACGAN;样本生成

中图分类号:TP206+.3 **文献标志码:**A **文章编号:**1671-5276(2019)06-0159-05

Method of Diagnosing Parametric Fault of Power Converter Based on Auxiliary Classifier Generative Adversarial Nets

FU Honghui, WANG Youren, SUN Canfei, SUN Quan

(College of Automation Engineering, Nanjing University of Aeronautics and Astronautics, Nanjing 211106, China)

Abstract: This paper proposes an intelligent method of diagnosing parametric fault based on auxiliary classifier generative adversarial nets (ACGAN). The voltage and current signals of the power converter are collected first, and then the time domain characteristics of the signal are extracted, which is used to constitute the fault feature vectors. The generator and discriminator are trained by the adversarial learning mechanism, and the pseudo-data similar to the real fault features are constructed by the generator in ACGAN, then the pseudo-data and the real data are simultaneously used to train the discriminator, and the generator is trained by discriminator discriminating the real or fake data. Buck converter is taken as an example, the feasibility of this method is verified by the simulation. The results show that ACGAN fault diagnosis method has higher fault diagnosis rate and better generalization performance than the traditional neural network.

Keywords: fault diagnosis; adversarial learning mechanism; power converter; deep learning; ACGAN; sample generation

0 引言

随着电力电子技术的发展,功率变换电路广泛应用于工业、军事、航空航天、新能源发电等领域。由于功率变换器在工作中处于高电压和大电流的工作状态,易导致电子元器件发生损坏,甚至可能引发安全事故。因此功率变换器故障诊断技术研究具有重要的现实意义^[1-2]。

随着机器学习理论的迅速发展,电力电子电路智能故障诊断技术已成为当前国内外研究热点与发展方向。目前应用于电力电子的智能故障诊断算法主要有神经网络^[3-4]、模糊逻辑^[5-6]等。文献[7]提出基于极限学习机的三电平光伏逆变器故障诊断方法,该方法能够对功率器件的单故障和多故障模式进行诊断。文献[8]利用小波分解和核主成分分析提取特征,使用概率神经网络分类器对多电平变换器进行故障诊断。文献[9]提取三电平逆变器桥臂电压的谐波幅值和相位作为故障特征信息,采用多神经网络结构和算法,诊断单器件开路和多个器件同时

开路的多故障模式。文献[10]以变流器输出三相电流信号为特征参数,运用小波分析对电流信号进行降噪,通过FFT变换得到故障特征向量,采用BP神经网络进行故障诊断。目前电力电子电路智能故障诊断研究集中于结构性故障诊断,而对参数性故障诊断研究较少。另一方面这类诊断方法较多采用传统的浅层神经网络,存在训练不稳定,容易陷入局部最优的缺点,导致模型泛化能力差。而采用多个隐含层的深度神经网络,虽然学习能力得以提高,但层数的增加会导致模型过拟合加重,泛化性能降低,使得诊断能力较差。

GOODFELLOW提出的生成对抗网络(generative adversarial nets, GAN)^[11]目前已经广泛应用于图像处理和自然语言处理等领域。这种新的深度学习模型采用生成器和判别器互相竞争的新学习方式,生成器得到的伪数据和真实数据同时用于训练判别器,通过对抗学习机制、增加新样本的方法,能够同时提高判别器的判别能力和生成器的生成能力,以此提升神经网络的学习和泛化能力。

本文提出一种基于辅助分类生成对抗网络(auxiliary

基金项目:南京航空航天大学研究生创新基地(实验室)开放基金资助(kfj20170323);中央高校基本科研业务费专项资金资助

作者简介:傅宏辉(1993—),男,浙江宁波人,硕士研究生,研究方向为电力电子电路健康管理。

classifier GAN, ACGAN)^[12]的功率变换器参数性故障诊断方法。该方法提取测点电压信号和支路电流信号的时域特征,将特征输入至ACGAN,通过ACGAN生成器生成伪数据并与真实数据一同训练判别器,令生成器和判别器迭代对抗训练,再将测试样本输入至训练完成的ACGAN判别器进行故障诊断,最后以Buck电路为例验证了该方法的有效性。

1 辅助分类生成对抗网络

1.1 结构原理

1) ACGAN 计算结构

辅助分类生成对抗网络ACGAN由生成器和判别器构成,其计算结构如图1所示。ACGAN具有样本生成和多分类功能。




图1 ACGAN 计算结构

生成器的输入是随机向量 z 和输入样本的类别标签 c ,判别器的输入是真实数据 X_{real} 和伪数据 X_{fake} 。其中 X_{fake} 为由 G 生成的尽可能服从真实数据分布的样本。如果判别器的输入来自真实数据 X_{real} ,标注为1;如果输入数据为 X_{fake} ,标注为0。在此 D 的目标是实现对数据来源的二分类判别:真(源于真实数据 X_{real} 的分布)或者伪(来源于生成器的伪数据 X_{fake})以及对输入数据的多分类。 G 的目标是使自己生成的伪数据 X_{fake} 在 D 上的表现 $D(X_{fake})$ 和真实数据 X_{real} 在 D 上的表现 $D(X_{real})$ 一致。 D 和 G 相互对抗并迭代优化,使得 D 判别真伪的性能和 G 生成近似真实数据的性能一同提升,当 D 判别真伪的能力提升到一定程度,而且无法正确判别数据的来源时,GAN即达到纳什均衡,则认为生成器 G 学习到真实数据的分布。

2) 生成器和判别器

GAN中的生成器和判别器可以为任意的神经网络,本文中ACGAN生成器和判别器的结构设计为全连接层神经网络,即每一层的任意一个神经元节点都和下一层的所有节点连接,下一层的每个节点在计算时,激活函数的输入是上一层的所有节点的加权,如图2所示。

图2a)中生成器的输入是由取自均匀分布的随机向量 z 和独热编码标签向量 c 组成的向量 $V=[z, c]$ 。生成器隐含层输出为:

$$h_G = s_{Ch}(W_{Ch}V + b_{Ch}) \quad (1)$$




图2 生成器和判别器的网络结构

其中: s_{Ch} 是隐含层的激活函数,为ReLU函数,其表达式为 $\phi(x) = \max(0, x)$; W_{Ch} 和 b_{Ch} 是生成器隐含层的权重和偏置项。

生成器输出层的输出为:

$$X_{fake} = s_{Co}(W_{Co}h_G + b_{Co}) \quad (2)$$

式中: X_{fake} 是生成器输出得到的伪数据; s_{Co} 是输出层的激活函数,为Sigmoid函数,其表达式为 $\phi(x) = \frac{1}{1+e^{-x}}$; W_{Co} 和 b_{Co} 是输出层的权重和偏置项。

如图2b)所示判别器的输入是原始数据 X_{real} 和 X_{fake} ,判别器的隐含层输出为:

$$h_D = s_{Dh}(W_{Dh}X + b_{Dh}) \quad (3)$$

其中: s_{Dh} 是隐含层的激活函数,为ReLU函数; W_{Dh} 和 b_{Dh} 是判别器隐含层的权重和偏置项。

判别器输出层的输出为:

$$\begin{cases} C = s_{Dol}(W_{Dol}X + b_{Dol}) \\ B = s_{Dol2}(W_{Dol2}X + b_{Dol2}) \end{cases} \quad (4)$$

其中: s_{Dol} 判别器为多分类输出层的激活函数为Softmax函数,其表达式为 $\phi_i(x) = \frac{e^{x_i}}{\sum_{i=1}^N e^{x_i}}, i=1, 2, \dots, N$; s_{Dol2} 为真假输出层的激活函数,为Sigmoid函数; W_{Dol} 、 W_{Dol2} 、 b_{Dol} 和 b_{Dol2} 为输出层的权重和偏置项。

判别器多分类输出为 $C=[c_1, c_2, c_3, \dots, c_N]$, c_i 为数据属于第 $i(i=1, 2, 3, \dots, N)$ 个类别的概率, B 是判别器的真假(1/0)二值输出。

1.2 对抗学习机制

ACGAN训练过程的本质是生成器 G 和判别器 D 的零和游戏,两者的优化过程是基于博弈论的极大极小问题^[13]。

ACGAN具体训练步骤如下:

步骤1:训练判别器 D :将随机向量 z 输入至生成器 G ,生成伪数据 X_{fake} ,标注为0,并附带对应类别标签 c ,真实数据 X_{real} 标注为1,同样附带对应的类别标签 c ,与伪数据一同输入至判别器 D ,判别器 D 同时判别数据的真伪和数据的类别,最大化判别器的目标函数:

$$L_D = [\log B_{real} + \log(1 - B_{fake}) + \log C_{real} + \log C_{fake}] \quad (5)$$

其中: C_{real} 是真实数据输入判别器后多分类输出的类别概率, C_{fake} 是伪数据输入判别器后多分类输出的类别概率; B_{fake} 是伪数据输入判别器后的真假(1/0)二值输出, B_{real} 是真实数据输入判别器的真假二值输出。

通过反向传播算法计算判别器的参数集 $\theta_d = \{W_{Dh}, W_{Do1}, W_{Do2}, b_{Dh}, b_{Do1}, b_{Do2}\}$ 中各参数的梯度值,并通过随机梯度下降优化算法求得判别器目标函数的最优解。

步骤2:训练生成器 G:将随机向量 z 输入至生成器 G,生成伪数据 X_{fake} ,并附带对应类别标签 c ,伪数据和真实数据 X_{real} 一同标注为 1,输入至判别器 D,当判别器 D 判别出伪数据 X_{fake} 为假时(输出标注为 0),说明生成器 G 生成的伪数据 X_{fake} 未能成功欺骗判别器 D,为了使生成器 G 生成的伪数据能够成功欺骗判别器 D,最大化生成器的目标函数:

$$L_c = [\log B_{fake} + \log C_{real} + \log C_{fake}] \quad (6)$$

通过反向传播算法计算生成器的参数集 $\theta_c = \{W_{Gh}, W_{Go}, b_{Gh}, b_{Go}\}$ 中各参数的梯度值,并通过随机梯度下降优化算法求得生成器目标函数的最优解。

步骤3:重复步骤1和步骤2,迭代训练判别器 D 和生成器 G,直至达到纳什均衡,即判别器 D 真伪分辨率为 50%。

训练完成后得到的判别器模型将用于故障诊断。

2 功率变换器故障诊断算法

本文提出一种基于辅助分类生成对抗网络的功率变换器故障诊断方法。该方法通过 ACGAN 中的生成器生成与真实数据分布近似的伪数据样本。将真实数据样本与伪数据样本同时用于判别器训练,提高判别器的泛化能力。

基于 ACGAN 的功率变换器故障诊断流程如图 3 所示,具体实现步骤如下:

1) 获取测点电压值和支路电流值,提取信号时域特征,将归一化后的数据样本分为训练集和测试集。

2) 迭代训练生成器 G 和判别器 D。首先将生成器生成的数据与训练集数据同时输入至判别器来训练判别器,然后将训练完的判别器网络参数固定,生成器再次生成数据后输入至判别器,通过误差反传训练生成器。反复训练,直至达到纳什均衡。

3) 将测试样本输入至 ACGAN 判别器,进行功率变换器故障诊断,分析诊断结果。

3 实验与结果分析

3.1 诊断电路实例

a) Buck 变换器电路

1) 电路原理

在 Saber 仿真软件中建立 Buck 电路模型,其等效主电路的原理图如图 4 所示。其中 S 表示开关管, R_{on} 是 MOSFET 的导通电阻,标称值为 0.27Ω ,容差为 $\pm 5\%$; Q 表示二极管, R_D 表示二极管的内阻,标称值为 0.2Ω ,容差为 $\pm 5\%$, u_d 表示二极管的导通压降, U_D 表示二极管端电压; L 表示理想电感,电感值标称值 $200 \mu H$,容差为 $\pm 20\%$, i_L 表示电感电流; R_L 为电感的内阻,标称值为 0.2Ω ,容差为

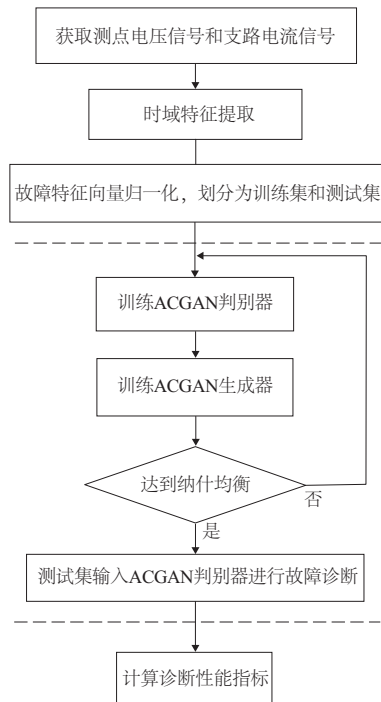


图 3 功率变换器故障诊断流程图

$\pm 5\%$; C 表示理想电容,电容值标称值为 $1\ 500 \mu F$,容差为 $\pm 20\%$, ESR 为电容的等效串联电阻,标称值为 0.08Ω ,容差为 $\pm 5\%$ 。 V_{in} 为输入电压, V_o 为输出电压, i_{in} 为输入电流, R 表示负载电阻。




图 4 Buck 电路等效电路图

2) 故障模式

Buck 变换电路中频发故障的元器件主要包括功率 MOSFET、二极管、电容、电感。本文考虑单个元器件发生参数性故障的情况。故障设置如表 1 所示,其中序号 1 表示电路正常状态模式,序号 2-序号 12 分别对应一种器件参数性故障状态模式。

表 1 Buck 电路状态模式

状态模式序号	状态模式说明
1	各器件在容差范围内正常工作
2	电容值减小 20%~40%, ESR 增大 5%~65%
3	电容值减小 40%~60%, ESR 增大 65%~125%
4	电容值减小 60%~80%, ESR 增大 125~185%
5	电感值减小 20%~40%, 等效电阻增大 5%~25%
6	电感值减小 40%~60%, 等效电阻增大 25%~45%
7	二极管导通电阻增大 5%~15%

续表 1

状态模式序号	状态模式说明
8	二极管导通电阻增大 15%~25%
9	二极管导通电阻增大 25%~35%
10	MOSFET 导通电阻增大 5%~15%
11	MOSFET 导通电阻增大 15%~25%
12	MOSFET 导通电阻增大 25%~35%

b) 故障特征提取

将 Buck 电路各测点信号的最大值、最小值、平均值等作为故障特征参数,得到表 2 特征参数。根据表 2 构建 15 维故障特征向量: $f=[V_{in}, i_{in_max}, i_{in_min}, i_{in_mean}, V_{out_max}, V_{o_min}, V_{o_mean}, V_{o_pp}, V_{o_ppr}, i_{L_max}, i_{L_min}, U_{Dp_max}, U_{Dp_min}, U_{Dn_max}, U_{Dn_min}]$ 。

表 2 Buck 电路故障特征参数

监测信号	特征参数
输入电压 V_{in}	输入电压 V_{in}
输入电流 i_{in}	输入电流最大值 i_{in_max} 、输入电流最小值 i_{in_min} 、输入电流均值 i_{in_mean}
输出电压 V_o	输出电压最大值 V_{o_max} 、输出电压最小值 V_{o_min} 、输出电压均值 V_{o_mean} 、输出电压纹波 V_{o_pp} 、输出电压纹波比 V_{o_ppr}
电感电流 i_L	电感电流最大值 i_{L_max} 、电感电流最小值 i_{L_min}
二极管端电压 U_D	二极管端电压正值最大值 U_{Dp_max} 、二极管端电压正值最小值 U_{Dp_min} 、二极管端电压负值最大值 U_{Dn_max} 、二极管端电压负值最小值 U_{Dn_min}

c) 样本数据集

在 Saber 仿真环境下对 20 种工况下 12 种状态模式分别进行 100 次蒙特卡洛分析,设计电路开关频率为 20 kHz,采样频率设置为 2 MHz,即一个开关周期内采样 100 个数据点,选取电路稳态时的 200 个点作为最终提取特征的信号。每种状态模式各得到 100 组测点信号数据,总共得到 1 200 组测点信号数据。根据表 2 对每组测点数据进行特征提取,最终每组数据得到 15 维特征向量,采用式(7)最大最小值法将 1 200 组 15 维数据的每一维归一化到 0~1。

$$y = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (7)$$

其中 x_{max} 、 x_{min} 分别为 1 200 组数据每一维特征参数的最大值和最小值。

为了获取均衡的训练集数据,分别在 20 种工况下的每种状态模式取 1 组数据,共 240 组,该部分数据用于测试集数据,其余 960 组数据作为训练集。

3.2 故障诊断结果分析

本文诊断算法均在 Python 环境下使用 Google 研发的

Tensorflow 框架编程实现,计算机系统为 Windows 7,内存为 16 GB,Intel Core i7-6700 CPU,主频为 3.4 GHz。

本文利用 BP 神经网络模型、多层感知器 (MLP) 与 ACGAN 作为诊断效果比对。BP 神经网络结构经过优选之后选择 15-40-12;MLP 结构经过优选之后选择 15-150-50-20-12;为比较 ACGAN 算法的特点,设置 ACGAN1 模型判别器结构为 15-30-12,生成器结构为 5-100-15;设置 ACGAN2 模型判别器结构为 15-150-50-20-12,生成器结构同 ACGAN1;设置 ACGAN3 模型为 ACGAN 优选后的结构。训练批量设置为 240,学习率设置为 0.001,优化方法采用 Adam 算法。每种模型训练 4 次,计算其平均诊断准确率(图 5)。




图 5 五种诊断模型比较

由图 5 可知,在均衡数据集下,MLP 的诊断准确率明显高于 BPNN,说明传统深度神经网络具有比浅层神经网络更好的诊断效果。将 ACGAN1 和 BPNN 的诊断结果相比较,说明在浅层神经网络中,对抗学习机制能够提高模型的泛化性能和判别器的诊断能力。由 ACGAN2 和 MLP 诊断结果比较得知,在神经网络中应用对抗学习机制,同样能够提高传统深度神经网络的诊断能力。而经过结构优选的 ACGAN3,具有更好的诊断性能,说明对抗学习机制能够提升神经网络的泛化性能,提高智能故障诊断准确率。

根据 BPNN、MLP 和 ACGAN 的诊断准确率误差线可知,BPNN 和 MLP 诊断结果的误差明显大于 ACGAN,说明对抗学习机制能够使得训练神经网络模型更加稳定。

4 结语

本文提出了一种基于 ACGAN 的功率变换器参数性故障智能故障诊断方法,通过实验结果分析得到如下结论:

1) ACGAN 通过对抗学习机制,同时训练生成器与判别器,提高了判别器的诊断准确率和泛化性能,且训练得到的神经网络模型更加稳定。生成器增加的新样本能够扩充训练样本集,提高判别器泛化性能。

2) 基于 ACGAN 的功率变换器参数性故障诊断方法,故障诊断准确率明显优于 BP 神经网络和 MLP 故障诊断方法。

3) 神经网络对参数性故障诊断的诊断准确率要高于浅层神经网络。

参考文献:

- [1] GIVI H, FARJAH E, GHANBARI T. Switch fault diagnosis and capacitor lifetime monitoring technique for DC-DC converters

- using a single sensor[J]. Iet Science Measurement & Technology, 2016, 10(5):513-527.
- [2] CHENG S, LI W, DING R J, et al. Faultdiagnosis and fault-tolerant control scheme for open-circuit faults in three-stepped bridge converters[J]. IEEE Transactions on Power Electronics, 2016, 32(3):2203-2214.
- [3] YE F, ZHANG Z, CHAKRABARTY K, et al. Board-level functional fault diagnosis using artificial neural networks, support-vector machines, and weighted-majority voting[J]. IEEE Transactions on Computer-Aided Design of Integrated Circuits and Systems, 2013, 32(5):723-736.
- [4] MOOSAVI S S, DJERDIR A, AIT-AMIRAT Y, et al. Artificial neural network-based fault diagnosis in the AC-DC converter of the power supply of series hybrid electric vehicle[J]. Iet Electrical Systems in Transportation, 2016, 6(2):96-106.
- [5] CHEN W, BAZZI A. Logic-based methods for intelligent fault diagnosis and recovery in power electronics[J]. IEEE Transactions on Power Electronics, 2017, 32(7):5573-5589.
- [6] WANG T, ZHANG G, ZHAO J, et al. Fault diagnosis of electric power systems based on fuzzy reasoning spiking neural p systems[J]. IEEE Transactions on Power Systems, 2015, 30(3):1182-1194.
- [7] 姜媛媛, 王友仁, 吴祎, 等. 基于小波包能量谱和 ELM 的光伏逆变器多故障在线诊断[J]. 仪器仪表学报, 2015, 36(9):2145-2152.
- [8] 于生宝, 何建龙, 王睿家, 等. 基于小波包分析和概率神经网络的电磁法三电平变换器故障诊断方法[J]. 电工技术学报, 2016, 31(17):102-112.
- [9] 陈丹江, 叶银忠. 基于多神经网络的三电平逆变器器件开路故障诊断方法[J]. 电工技术学报, 2013, 28(6):120-126.
- [10] 梅樱, 孙大南, 韦中利, 等. 一种基于矢量控制的变流器故障诊断方法[J]. 电工技术学报, 2010, 25(3):177-182.
- [11] GOODFELLOW I J, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial networks[J]. Advances in Neural Information Processing Systems, 2014(3):2672-2680.
- [12] ODENA A, OLAH C, SHLENS J. Conditional image synthesis with auxiliary classifier gans[EB/OL]. ArXiv Preprint: 1610.09585, 2016. <https://arxiv.org/pdf/1610/09585.pdf>
- [13] 王坤峰, 苟超, 段艳杰, 等. 生成式对抗网络 GAN 的研究进展与展望[J]. 自动化学报, 2017, 43(3):321-332.

收稿日期:2018-10-08

(上接第 136 页)

参考文献:

- [1] 史信芳, 蒋庆东, 李春雷, 等. 自动扶梯[M]. 北京:机械工业出版社, 2014(5):10-57.
- [2] 师访. ANSYS 二次开发及应用实例详解[M]. 北京:中国水利水电出版社, 2012:389-371.
- [3] ANSYS, INC. ANSYS 17.0 Help[Z]. Canonsburg, PA: ANSYS, INC, 2017.
- [4] 明日科技. Visual C++2013 从入门到精通[M]. 北京:清华大学出版社, 2017.
- [5] 刘标, 程文明, 栗园园. 基于 VB 和 APDL 的门式起重机结构

参数化有限元分析[J]. 起重运输机械, 2010(12):12-13.

- [6] 詹光源. 自动扶梯桁架的有限元分析[J]. 电梯工业, 2015(7):61-64.
- [7] 张红兵, 万长东, 尚广庆, 等. 自动扶梯桁架结构的有限元轻量化分析[J]. 机械工程, 2012, 29(10):1139-1142.
- [8] 高原, 曹国华, 秦健聪. 船用自动扶梯桁架的有限元分析及其应用[J]. 机械强度, 2017(3):78-80.
- [9] 陈杨. 基于 ANSYS 的扶梯桁架结构自动化建模与分析系统开发[D]. 南京:南京航空航天大学, 2016.

收稿日期:2019-08-01

(上接第 138 页)

3 结语

随着极地研究的不断深入, 冰区船舶的需求量将增大, 船舶的冰区结构加强设计成为冰区船舶要解决的问题之一, 在船舶设计过程中也是一大重点和难点。本文以 3950 kW 极地科考船为例, 在两个极限工况下对其进行冰区加强的计算与分析, 优化设计, 改进不合理的布局和结构, 最终该项目舵桨箱体的安全性能满足冰区要求。通过有限元数值模拟分析优化, 对舵桨水下箱体的可靠性进行了有效分析, 提高了舵桨推进器整体系统在冰区航行的安全性。通过结合冰区理论计算和有限元数值模拟分析, 对舵桨水下箱体进行模拟分析和优化计算, 可为后续冰区舵桨推进器进一步研发设计提供参考依据。

参考文献:

- [1] 王博. 考虑船-冰相互干扰的冰区航行舰船冰载荷计算方法研究[D]. 哈尔滨:哈尔滨工程大学, 2018.
- [2] 杜平安, 于亚婷, 刘建涛. 有限元法—原理建模及应用[M]. 北京:国防工业出版社, 2004.
- [3] 陈聪. 冰撞载荷作用下船体结构抗冲击设计研究[D]. 镇江:江苏科技大学, 2015.
- [4] 季明迎, 岳前进. 工程海冰数值模型及应用[M]. 北京:北京科学出版社, 2011.
- [5] 张宇明, 李德祥. 大型船舶冰区结构加强技术研究[J]. 造船技术, 2000(2):14-17.
- [6] 孙鸣远. 冰区航行船舶在冰载荷作用下的局部结构强度分析研究[D]. 哈尔滨:哈尔滨工程大学, 2015.

收稿日期:2019-10-30