

DOI: 10.19650/j.cnki.cjsi.J2108020

基于 IGA-BP 神经网络的智能电能计量 设备退化趋势研究*

马 健,滕召胜,邱 伟,马丽莎,刘 颀
(湖南大学电气与信息工程学院 长沙 410082)

摘 要:电能计量设备可靠运行与否影响着电网边缘测量与电量计量准确性,为此本文提出一种基于参数优化 BP 神经网络的设备退化趋势分析方法。结合国网新疆高干热试验基地,及其智能电能计量设备实时运行基本误差数据,利用 Spearman 相关性分析方法,提取影响智能电能计量设备基本误差值的主要环境应力;采用函数拟合插值(FFI)方法消除原始数据中缺失值对退化分析的影响,建立基于 BP 神经网络的智能电能计量设备退化研究模型;最后,引入改进遗传算法(IGA)优化 BP 神经网络参数,实现智能电能计量设备退化趋势的向后预测与更新。选取基地中不同型号的若干个智能电能计量设备进行多项实验,结果表明本文模型具有较高的预测能力,预测结果的平均均方根误差为 0.012 3,预测准确度最高可达 90.2%。

关键词:智能电能计量设备;退化趋势;BP 神经网络;改进遗传算法

中图分类号: TM933.4 TH17 **文献标识码:** A **国家标准学科分类代码:** 470.40

Research on the degradation trend of smart energy metering equipment based on IGA-BP neural network

Ma Jian, Teng Zhaosheng, Qiu Wei, Ma Lisha, Liu Jie

(College of Electrical and Information Engineering, Hunan University, Changsha 410082, China)

Abstract: The reliable operation or not of smart energy metering equipment affects the accuracy of grid edge measurement and electricity metering. For this reason, this paper proposes an equipment degradation trend analysis method based on parameter optimization BP neural network. Combining with the State Grid Xinjiang High Dry Heat Test Base and the basic error data of the real-time operation of the smart energy metering devices, the Spearman correlation analysis method is used to extract the main environmental stress that affects the basic error value of the smart energy metering equipment; the function fitting interpolation (FFI) is used to eliminate the influence of missing values in the original data on degradation analysis. A BP neural network-based smart energy metering equipment degradation research model is established. Finally, an improved genetic algorithm (IGA) is introduced to optimize the BP neural network parameters to realize the backward forecast and update of the degradation trend of smart energy metering equipment. Several smart energy metering devices with different types in the base were selected to conduct various kinds of experiments. The results show that the model proposed in this paper has a high predictive ability. The average root mean square error of the prediction results is 0.012 3, and the prediction accuracy is up to 90.2%.

Keywords: smart energy metering equipment; degradation trend; BP neural network; improved genetic algorithm

0 引 言

电能计量仪器作为电网末梢的关键设备,其可靠性关系到电网建设中的电能双向计量、设备健康监测与电

费准确计算。设备退化趋势研究是设备可靠性设计的主要研究目标^[1]。随着我国智能电网的高速发展,智能电能计量设备的退化趋势研究与运行可靠性评估对智能电网建设与电量准确计量具有重要的经济价值与社会意义。

收稿日期:2021-05-31 Received Date: 2021-05-31

* 基金项目:国家电网有限公司科技项目(5230HQ19000F)、国家自然科学基金(52077067)项目资助

针对智能电能计量设备运行可靠性评价与预估问题,主流的研究方法有以下几个方面:1)基于设备的故障机理或现场故障数据分析设备可靠性^[2];2)利用可靠性评估手册探究智能电能计量设备可靠性^[3]。但上述研究需要提前知晓关键元器件参数或参考可靠性预计手册,这对智能电能计量设备可靠性的研究带来了一定的局限性^[4]。为克服这一局限性,本文从退化趋势角度对智能电能计量设备可靠性进行研究。随着现代化设备性能不断提高,设备的实际失效数据难以在正常运行状况下得到,因此,从设备退化趋势角度研究可靠性的优势在于可根据设备正常运行的历史数据建立设备退化模型以预估其可靠性。

王宇等^[5]基于离群点检测的方法对产品性能退化进行了评估,该方法对风电机组的退化趋势研究和寿命预测具有一定的可行性,但该方法没有考虑具体工况和环境因素带来的影响。文献[6]利用采集到的道岔非故障功率数据提取特征参数,再基于 SOM-BP 混合神经网络实现对道岔设备退化状态的识别,结果表明该方法具有一定的准确性。冯珂等^[7]提出一种基于连续时间马尔可夫退化过程的牵引供电设备可靠性预测方法,实证分析表明,该方法能够有效地利用历史数据对设备可靠性进行预测。退化建模对设备剩余寿命预测也有一定的参考意义^[8],当设备退化趋势达到失效阈值时,设备需要及时检修或更换以避免产生不必要的事故。

利用数据驱动与机器学习相结合是当前设备退化研究的主流趋势^[9],文献[10]构建了数据驱动的旋转设备性能退化趋势预测模型,依据此模型准确预测并追踪旋转设备性能退化趋势的发生和发展;文献[11]提出了一种性能数据驱动的产品关键设计参数识别方法,利用该方法能够识别出导致性能严重退化的关键设计参数。此类方法的主要优点在于适应性强,非线性拟合能力强,不需提前得到失效机理或提前设定退化模型,从而避免了模型选取不当对拟合精度的严重影响^[12]。

智能电能计量设备退化数据具有数据量大、噪声含量高的特点,且典型环境下智能电能计量设备退化趋势受多种应力的影响,针对此特点,神经网络的非线性映射能力和多应力融合能力在智能电能计量设备退化趋势研究中具备一定的应用潜力^[13]。基于样本数据量大的特点,本文选取结构较为简单的 BP (back-propagation) 神经网络作为智能电能计量设备退化趋势研究的基本方法。同时,BP 神经网络对样本中的异常值敏感度不高,相比于支持向量机(support vector machine,SVM)等其他机器学习方法更适用于退化数据分析。传统 BP 神经网络在实际应用中仍然具有一定局限性。例如,网络初始权值

和阈值随机设定易导致训练过程中陷入局部极小,同时也会影响收敛速度^[14]。

为解决上述问题,本文提出一种改进遗传算法(improved genetic algorithm,IGA)对传统 BP 神经网络进行优化,实现智能电能计量设备退化趋势的准确预测。遗传算法具备较强的全局搜索寻优能力^[15],但其反复迭代过程使得算法收敛速度过慢,尤其是当样本数据量较大时影响更加明显。相比传统遗传算法而言,IGA 通过改进遗传操作中的选择算子以提高算法的收敛速度^[16]。将 IGA-BP 模型应用于智能电能计量设备退化趋势研究中,多个样本仿真结果表明,该模型具有良好的预测能力,有效地解决了智能电能计量设备的退化趋势分析问题,为智能电能计量设备的可靠性评估提供了强有力的技术支撑。

1 智能电能计量设备退化数据分析

1.1 退化数据可视化

智能电能计量设备在正常运行过程中受自然环境和电应力等因素影响较大,会存在运行基本误差,随着运行时间增加,其基本误差也会随之增大,当达到某一阈值时,判定该设备失效^[17]。智能电能计量设备运行基本误差表征了智能电能计量设备在正常运行时的测量误差,该误差由其自身特性和环境因素共同作用产生,随着智能电能计量设备运行时间的推移,其基本误差也会随之增加,即基本误差值随时间的变化规律反映了智能电能计量设备的退化趋势。因此,本文选取基本误差值作为智能电能计量设备的退化指标。

为研究典型环境下智能电能计量设备的退化趋势,本文选用在新疆地区运行且由不同公司生产的一批智能电能计量设备作为研究对象,选取 3 家公司的智能电能计量设备在 2017 年 12 月至 2020 年 1 月的基本误差数据和环境应力数据进行退化趋势研究,每家公司选取 5 个样本进行对比。

原始数据中的时间数据均以年月日形式储存,对此,以日为最小时间间隔做量化处理,以处理后的时间数据为横坐标,智能电能计量设备运行基本误差值为纵坐标,3 家公司各个样本的退化趋势如图 1 所示。

图 1 展示了 3×5 个样本的退化趋势,由图 1 可见:同一家公司的不同样本呈现出大致相同的退化趋势,不同公司的样本之间虽有差异,但所有样本具有一个共同特点,即基本误差在时间维度上具有一定的周期性,周期约为一年,温度、湿度等环境应力在时间维度上也呈现一定的周期性,周期同样约为一年,表明智能电能计量设备在运行过程中对环境具有极强的依赖度,而更依赖于何种环境应力可以利用相关性进行分析。




图 1 各样本原始退化数据

Fig. 1 The original degradation data of various samples

1.2 相关性分析

原始数据中包含有温度(T)、湿度(R)、气压(P)、风速(W)、紫外线(U)等各种环境应力,结合数据的时序性特点,采用斯皮尔曼(Spearman)相关性分析法,计算基本误差(E)和各环境应力的相关系数,结果如表 1 所示。表 1 表明基本误差值与温度具有很强的正相关性,与气压具有很强的负相关性,相关系数绝对值达 0.8 以上,同时与湿度也呈现出较强的相关性,相关系数绝对值接近 0.8,而与风速和紫外线的相关性不高。该相关性分析说明基本误差对温度、气压以及湿度有着较强的依赖度,表明智能电能计量设备的退化趋势受温度、气压和湿度的影响较大。因此选取温度、气压和湿度作为典型环境应力因子探究环境应力叠加效应对基本误差的影响。

表 1 变量的相关性分析

Table 1 Correlation analysis of the variables

参数	环境应力				
	T	R	P	W	U
E	0.941 62	-0.796 13	-0.897 54	0.421 72	0.538 05

1.3 数据预处理

如图 1 所示,原始退化数据在时间维度上存在较多空值,为探究智能电能计量设备基本误差随时间的退化

趋势以及提高模型的预测准确度,应保证基本误差数据在时间维度上的连续性。传统的插值方法大多采用单点依次插值,在处理大样本数据时效率很低,本文提出一种函数拟合插值(function fitting interpolation, FFI)方法对缺失数据进行填补,该方法在提高数据处理效率时又不失准确度。具体操作方法如下:

1) 基于原始数据点采用函数拟合的方法拟合出基本误差值随时间的变化趋势,依据原始数据的特点,采用正弦叠加函数进行拟合:

$$f(x) = \sum_{n=1}^m a_n \sin(b_n x + c_n) \quad (1)$$

式中: m 为正弦函数的项数; a_n 为幅值,由拟合数据的最值决定; b_n 为角频率,由拟合数据所含谐波成分决定; c_n 为初相,由拟合数据的相对位置决定。

2) 根据式(1),计算缺失点处的函数值,将该函数值加上一个适当的噪声,所得值即为填补值。但所加噪声的大小会直接影响到填补值的质量,需要对其反复调整以达到最优效果。

3) 为验证所提方法的可行性,首先从原始数据中提取某些天 $[t_1, t_2, \dots, t_n]$ 的数据组成验证集数据,然后基于剩余的原始数据进行上述操作,之后将 $[t_1, t_2, \dots, t_n]$ 处得到的填补值与对应的验证集数据进行对比并计算二者的均方误差,通过反复调整所加噪声的大小,使得验证集数据的均方误差达到最小。验证结果表明,上述步骤所求得的填补值与其对应的原始数据最大偏差不超过 10%,表明该方法具有可行性。

依据以上步骤得到的插值填补结果如图 2 所示。




图 2 插值填补结果

Fig. 2 Interpolation filling result

依据上述方法,对选取的 15 个样本分别进行空值填补,如图 3 所示。

2 智能电能计量设备退化模型

智能电能计量设备的运行受环境因素的影响较大,探究多个典型环境应力对基本误差值的影响是分析智能




图3 空值填补后的退化趋势

Fig. 3 Degradation trend after empty value filling

电能计量设备运行可靠性的有效方法之一。在研究多变量对单变量的共同作用与联合影响方面, BP神经网络有着广泛的应用和较高的准确度。因此本文选取BP神经网络模型来探究各环境应力对智能电能计量设备退化趋势的影响。

2.1 智能电能计量设备BP神经网络模型

神经网络输入样本变量的数量和质量会对模型的权重更新以及输出有着较大的影响^[13], 因此如何选取神经网络的输入参量是最为关键的步骤之一。依据Spearman相关性分析选取得到的3个典型环境应力与基本误差值有着较强的相关性, 因此考虑将其作为输入参量的组成部分; 此外, 随着时间的推移, 智能电能计量设备内部元器件会发生一定老化, 从而影响基本误差值的变化趋势, 因此考虑将时间应力作为输入参量之一。BP神经网络模型的结构如图4所示。

如图4所示, 将筛选得到的环境应力参量与时间应力构成一组特征向量 $\mathbf{X}$ 作为网络输入, 对应的基本误差值作为输出:

$$\mathbf{X} = [T, P, R, t] \quad (2)$$

$$\mathbf{Y} = [E] \quad (3)$$

式中: T 为温度; P 为气压; R 为湿度; t 为时间; E 为基本误差值。




图4 BP神经网络模型

Fig. 4 BP neural network model

基于式(2)和(3)将BP神经网络模型确定为四输入单输出的网络模型。基于训练数据对各个神经元之间的连接权值不断更新, 可以拟合出自变量与因变量之间的映射关系, 即 $Y=f(X)$, 理论上, BP神经网络可以逼近任意函数。

2.2 改进遗传算法选择算子

传统BP神经网络由于其固有特性会存在一定的不足之处, 例如训练时容易陷入局部极小而导致预测精度不高、迭代次数过多导致收敛速度慢等问题^[14]。引入遗传算法优化BP神经网络可以有效地解决此类问题, 遗传算法的全局寻优能力可以为BP神经网络搜索出最优的网络初始权值和阈值^[15], 代替传统BP神经网络中随机设定的网络初始权值和阈值, 从而提高预测精度和收敛速度。实践表明, 传统遗传算法仍存在一定的不足, 例如计算量大导致计算时间增加、过早收敛导致未能得到最优解等问题。据此, 本文提出一种改进遗传算法对其进行优化, 以提高BP神经网络的预测精度。

遗传算法的实现关键在于遗传算法的基本操作, 即选择、交叉、变异。其中选择算子如何确定是选择操作中的最重要的环节, 应用最为广泛的有比例选择算子和最优保存策略^[18]。但在实际工程应用中二者均表现出一定的局限性, 比例选择算子存在随机性导致该方法存在一定的误差; 最优保存策略会淘汰最优个体以外的其他个体, 破坏了种群的完整性和多样性。

本文基于最优保存策略提出一种改进的选择算子确定方法, 该方法既保留了最优保存策略的优势, 又维护了种群的完整性。具体实现步骤如下: 1) 确定一个个体数量为 N 的初始种群, 分别计算种群内每个个体的适应度值; 2) 按照适应度值对所有个体进行升序排序, 劣者在前, 优者在后; 3) 将排序好的个体平均分成 n 组, 每一组的个体数相同, 但个体的平均适应度值不等; 4) 按照一定的比例 x 从各组中选择个体组成新的种群, 原则上适应度值越大的组选择比例越大, 即优者组多选, 劣者组少选; 5) 比例选择会使得新种群个体数量少于旧种群, 因此

从较优良的组中随机选取个体填补,使个体数量保持不变。上述操作一方面可以避免重复选择适应度值较低的个体,以提高选择操作的效率;另一方面通过控制比例 x 的大小可以保证种群个体的多样性不被破坏。

2.3 基于 IGA-BP 的智能电能计量设备退化研究

BP 神经网络在训练过程中需要不断调节网络的连接权值和阈值,初始权值和阈值选取不当会使得训练时间过长甚至陷入局部极小。因此,在确定网络结构之后,利用 IGA 的全局搜索能力筛选出 BP 网络的最佳初始权值和阈值,主要过程如下:

1) 种群初始化。遗传算法中对个体的编码方法主要有实数编码和二进制编码,本文为优化 BP 神经网络的权值和阈值,采用实数编码。种群数量根据经验确定,种群中的每个个体包含了神经网络的全部权值和阈值,即一个个体对应一个确定的网络模型。

2) 确定适应度函数。适应度函数的确定是遗传算法最关键的一步,为优化神经网络的权值和阈值,针对各个个体对应的网络模型进行训练,将训练后的预测输出和期望输出之间的误差绝对值之和作为个体适应度值 F ,计算公式为:

$$F = k \left(\sum_{i=1}^n \text{abs}(y_i - o_i) \right) \quad (4)$$

式中: k 为系数; n 为输出节点数; y_i 为 BP 神经网络第 i 个节点的期望输出; o_i 为第 i 个节点的预测输出。

3) 选择操作。基于式(4),计算种群中每个个体的适应度值,利用 2.2 节中的改进选择算子对个体进行选择处理。

4) 交叉操作。由于个体采用实数编码,所以交叉操作采用实数交叉法,第 k 个染色体 a_k 和第 l 个染色体 a_l 在 j 位的交叉操作方法如下:

$$\begin{cases} a_{kj} = a_{kj}(1-b) + a_{lj}b \\ a_{lj} = a_{lj}(1-b) + a_{kj}b \end{cases} \quad (5)$$

式中: b 为 $[0,1]$ 中的随机数。

5) 变异操作。按照一定的概率选取第 i 个个体的第 j 个基因 a_{ij} 进行变异,操作如下:

$$a_{ij} = \begin{cases} a_{ij} + (a_{ij} - a_{\max}) \times f(g) & r > 0.5 \\ a_{ij} + (a_{\min} - a_{ij}) \times f(g) & r \leq 0.5 \end{cases} \quad (6)$$

其中,

$$f(g) = r_2 \left(1 - \frac{g}{G_{\max}} \right)^2 \quad (7)$$

式中: $a_{\max}$ 和 $a_{\min}$ 分别为基因 a_{ij} 的上下界; r 和 r_2 均为随机数; g 为当前迭代次数; $G_{\max}$ 为最大进化次数。

基于上述 5 个步骤,从种群中选取出一个最佳个体,将该个体中包含的权值和阈值信息作为初始权值和阈值输入到 BP 神经网络中。

2.4 IGA-BP 的仿真测试

为探究改进遗传算法的可行性与泛化能力,以函数 $f(x, y, z) = x^2 + y^2 + z^2$ 为例^[16],分别采用 BP、GA-BP、IGA-BP 这 3 种网络对此非线性函数进行拟合。随机生成 2 000 组数据,1 900 组为训练集,100 组为测试集;BP 网络选取为 3-10-1 结构,最大训练次数为 100,学习率为 0.1;遗传算法种群规模确定为 20,交叉变异概率分别为 0.4、0.2,进化次数为 50。将测试集的均方误差(mean square error, MSE)作为评价指标,每种网络均重复运行 5 次以避免存在偶然性,结果如表 2 所示。

表 2 3 种模型的预测误差

Table 2 The prediction errors of three models

运行次数	BP	GA-BP	IGA-BP
1	17.212 7	1.043 4	0.375 6
2	17.435 4	2.495 6	1.009 1
3	13.987 6	1.160 0	1.536 4
4	15.779 5	1.182 7	0.745 0
5	16.619 5	0.889 2	0.512 5
平均	16.206 9	1.354 2	0.835 7

进一步比较 GA-BP 与 IGA-BP 的计算效率,对二者的运行时间与收敛进化次数进行分析对比,结果如表 3 所示。

表 3 遗传算法的改进效果

Table 3 Improved effect of genetic algorithm

运行次数	运行时间/s		收敛进化次数	
	GA-BP	IGA-BP	GA-BP	IGA-BP
1	74.575 8	61.032 1	45	22
2	71.212 2	59.571 2	40	25
3	74.926 6	63.654 5	39	26
4	79.292 5	66.100 5	41	29
5	76.001 6	60.110 6	37	31
平均	75.201 7	62.093 8	40.4	26.6

由表 2~3 可知,IGA-BP 对非线性函数的拟合能力强于其他二者,且具有更高的计算效率,证明所提出的改进遗传算法优化 BP 神经网络有着更好的表现,可用于实际工程应用。

3 实例分析

3.1 IGA-BP 神经网络模型的参数选取

BP 神经网络模型中隐含层节点数的不同会导致网络训练结果产生较大差异,但隐含层节点数的确定无法

用固定的公式求出,一般由经验确定,同时 BP 神经网络训练方式的不同会导致网络的性能产生很大的差异。通过对比不同的隐含层节点数与不同的训练方式对网络产生的训练误差,选定模型的最佳隐含层节点数与最佳训练方式,如图 5 所示。




图 5 训练方法及隐含层节点数对网络训练的影响

Fig. 5 The influence of training method and the number of hidden layer nodes on network training

图 5 最低点处对应的隐含层节点数为 11,最佳训练方式为 L-M 法,因此结合 2.1 节中确定的输入输出节点,设定 IGA-BP 神经网络模型为 4-11-1 结构,采用 L-M 法训练模型。

3.2 预测结果分析

为探究神经网络模型的拟合与预测能力,在时间维度上划分训练集与测试集,将训练集数据视为历史量,测试集数据视为未知量,利用历史量对模型进行训练,然后用未知量测试模型的预测能力。

测试结果如图 6 所示(每家公司各随机抽取一个样本为例)。图中虚线以左为训练集数据,以右为测试集数据。由于预测是概率事件,并且充分考虑随机性的影响,在得到预测输出曲线的基础上求取一个上下偏差 10% 的置信区间。从图 6 中可以看出,测试集数据大多落在置信区间内,验证了 BP 神经网络模型具有一定的预测能力。图 7 展示了虚线右侧的曲线以及 FFI 插值前后的模型预测效果对比,从图 7 中可以看出,基于插值前的数据集样本进行训练再预测的结果与原始值之间的偏差高于插值后,说明对原始数据做插值处理可以提高模型的预测准确度,同时也验证了样本数据量越大会使 BP 神经网络的预测效果越好。

图 6 中预测结果的置信区间与虚线右侧的原始数据点如图 8 所示。图 8 中显示原始数据点大多落在置信区间内,验证了模型具备良好的预测能力,为更好地定量分析并评价不同模型的预测效果,将测试集中原始数据点落在置信区间的百分比定义为预测准确度。




图 6 网络预测效果

Fig. 6 Network prediction effect




图 7 插值前后效果对比

Fig. 7 Effect comparison before and after interpolation




图 8 测试集数据点在置信区间的占比

Fig. 8 The proportion of the test set data points in the confidence interval

基于上述思路,将全部的 15 个样本带入 3 个不同的模型(BP、GA-BP、IGA-BP)训练并预测,得到每个样本对应每个模型的预测准确度(%)如图 9 所示。




图 9 3 种模型对比

Fig. 9 Comparison of three models

图 9 表明,IGA-BP 具有较高的预测准确度,依据对上面 3 个图的分析与对比,IGA-BP 模型能够很好地拟合各环境应力与时间应力叠加效应对智能电能计量设备基本误差值的影响效果,并且能够有效地利用智能电能计量设备的历史退化数据对智能电能计量设备的退化趋势向后预测,为后续研究打下了基础。

3.3 常用预测方法对比

为进一步评价本文模型的预测能力,选取几种常用的机器学习方法进行对比,包括 SVM^[19]、小波神经网络^[20](wavelet neural network, WNN)等类似于 BP 神经网络的机器学习方法。此外,引入粒子群算法(particle swarm optimization, PSO)优化 BP 神经网络模型与本文模型进行对比以评价遗传算法的优化能力。

几种模型的预测对比结果如表 4 所示。BP 神经网络模型在预测能力上略优于其他模型,造成这种结果的原因是:SVM 模型对样本数据的要求较为苛刻,而智能电能计量设备的退化数据含较多噪声,进而验证了 BP 神经网络模型具有一定的抗噪能力;WNN 模型采用的小波基函数中的伸缩因子和平移因子具有一定的随机性,从而影响网络性能。另一方面,经过改进后的遗传算法优化的 IGA-BP 模型的预测能力要显著优于其他模型。

表 4 不同模型预测结果对比

Table 4 Comparison of prediction results of different models

模型对比	预测结果均方根误差		
	A 公司	B 公司	C 公司
SVM	0.031 7	0.025 8	0.029 8
WNN	0.035 2	0.026 2	0.023 5
BP	0.031 1	0.022 5	0.022 9
PSO-BP	0.024 7	0.014 3	0.012 4
IGA-BP	0.016 9	0.009 3	0.010 6

4 结 论

智能电能计量设备测量准确性易受实际典型环境影响从而发生退化现象。考虑到智能电能计量设备的退化趋势受多种复杂应力叠加效应的影响,本文首先提出 FFI 对缺失值进行插值,实验结果表明,基于 FFI 插值数据具备更小基本误差。据此,本文提出一种基于改进遗传算法优化 BP 神经网络模型以探究智能电能计量设备性能退化变化趋势,该模型能有效拟合多种应力输入对误差输出之间的复杂关系。结合新疆地区高干热典型实验室的一批智能电能计量设备试验数据,选取不同公司的多个样本数据对本文所提出模型进行验证,不同方法对比结果表明 IGA 可有效优化模型参数,IGA-BP 具有较高的准确性和适用性。依据当前量测数据可准确地预测出其未来的退化趋势,从而对智能电能计量设备采取预防性更换、维护等相关措施,以延长该区域电能计量准确性。

参考文献

- [1] 周佑光. 基于循环神经网络的轴承性能退化趋势预测方法研究[D]. 北京:北京化工大学,2019.
ZHOU Y G. Research on prediction method of bearing performance degradation trend based on recurrent neural network [D]. Beijing: Beijing University of Chemical Technology, 2019.
- [2] ZHA G, HUANG X, KANG R. Smart meter lifetime evaluation based on multi-stress acceleration test method[J]. Journal of Beijing University of Aeronautics & Astronautics, 2015(4): 23-25.
- [3] HE S, WU H, WANG Y. Reliability assessment test for smart electrical energy meters based on failure mechanism[J]. Proceedings of the International Conference on Reliability, 2015(2): 209-219.

- [4] QIU W, TANG Q, YAO W X, et al. Probability analysis for failure assessment of electric energy metering equipment under multiple extreme stresses [J]. IEEE Transactions on Industrial Informatics, 2021, 17 (6): 3762-3771.
- [5] 王宇,李玉鹏,赵志华. 基于离群点检测的产品性能退化评估 [J]. 计算机集成制造系统, 2021, 27 (4): 1040-1051.
- WANG Y, LI Y P, ZHAO ZH H. Product performance degradation assessment based on outlier detection [J]. Computer Integrated Manufacturing Systems, 2021, 27 (4): 1040-1051.
- [6] 高利民,许庆阳,李锋,等. 基于 SOM-BP 混合神经网络的道岔设备退化状态研究 [J]. 中国铁道科学, 2020, 41 (3): 50-58.
- GAO L M, XU Q Y, LI F, et al. Research on the degradation state of turnout equipment based on SOM-BP hybrid neural network [J]. China Railway Science, 2020, 41 (3): 50-58.
- [7] 冯珂,林圣,张奥,等. 基于连续时间马尔可夫退化过程的牵引供电设备可靠性预测方法研究 [J]. 中国电机工程学报, 2017, 37 (7): 1937-1946.
- FENG D, LIN SH, ZHANG AO, et al. Research on the reliability prediction method of traction power supply equipment based on continuous time Markov degradation process [J]. Chinese Journal of Electrical Engineering, 2017, 37 (7): 1937-1946.
- [8] 张正新,胡昌华,司小胜,等. 双时间尺度下的设备随机退化建模与剩余寿命预测方法 [J]. 自动化学报, 2017, 43 (10): 1789-1798.
- ZHANG ZH X, HU CH H, SI X SH, et al. Stochastic degradation modeling and remaining life prediction method of equipment under dual time scales [J]. Journal of Automation, 2017, 43 (10): 1789-1798.
- [9] 邱伟,唐求,刘旭明,等. 基于 MBBS 的电能量设备故障率预估 [J]. 仪器仪表学报, 2019, 40 (1): 43-51.
- QIU W, TANG Q, LIU X M, et al. MBBS-based failure rate estimation of electric energy metering equipment [J]. Chinese Journal of Scientific Instrument, 2019, 40 (1): 43-51.
- [10] 张彬,章立军,罗久飞,等. 基于函数主元分析的多阶段退化过程建模与预测 [J]. 仪器仪表学报, 2019, 40 (7): 30-38.
- ZHANG B, ZHANG L J, LUO J F, et al. Modeling and prediction of multi-stage degradation process based on functional principal component analysis [J]. Chinese Journal of Scientific Instrument, 2019, 40 (7): 30-38.
- [11] 褚学宁,陈汉斯,马红占. 性能数据驱动的机械产品关键设计参数识别方法 [J]. 机械工程学报, 2021, 57 (3): 185-196.
- CHU X N, CHEN H S, MA H ZH. Identification method of key design parameters of mechanical products driven by performance data [J]. Journal of Mechanical Engineering, 2021, 57 (3): 185-196.
- [12] KARKULALI P, HYUNSEOK P, NAGARAJAN R. Prognosis of power MOSFET resistance degradation trend using artificial neural network approach [J]. Microelectronics Reliability, 2019, 100-101.
- [13] 李亚,刘丽平,李柏青,等. 基于改进 K-Means 聚类 and BP 神经网络的台区线损率计算方法 [J]. 中国电机工程学报, 2016, 36 (17): 4543-4552.
- LI Y, LIU L P, LI B Q, et al. Calculating the line loss rate based on improved K-Means clustering and BP neural networks [J]. China Journal of Electrical Engineering, 2016, 36 (17): 4543-4552.
- [14] 李奎,李晓倍,郑淑梅,等. 基于 BP 神经网络的交流接触器剩余电寿命预测 [J]. 电工技术学报, 2017, 32 (15): 120-127.
- LI K, LI X B, ZHENG SH M, et al. Prediction of residual electrical life of AC contactors based on BP neural network [J]. Journal of Electrical Engineering, 2017, 32 (15): 120-127.
- [15] 金燕,刘少军,张建阁. 基于遗传算法优化的人工神经网络下高速滚动轴承的疲劳可靠性 [J]. 航空动力学报, 2018, 33 (11): 2748-2755.
- JIN Y, LIU SH J, ZHANG J G. Fatigue reliability of high-speed rolling bearings under artificial neural network optimized by genetic algorithm [J]. Journal of Aerodynamics, 2018, 33 (11): 2748-2755.
- [16] 刘浩然,赵翠香,李轩,等. 一种基于改进遗传算法的神经网络优化算法研究 [J]. 仪器仪表学报, 2016, 37 (7): 1573-1580.
- LIU H R, ZHAO C X, LI X, et al. A neural network optimization algorithm based on improved genetic algorithms [J]. Chinese Journal of Scientific Instrument, 2016, 37 (7): 1573-1580.
- [17] WANG X W, WU D, YUAN R M, et al. Dynamic test signal modelling and a compressed sensing-based test for electric energy meter errors [J]. Measurement, 2020, 164: 107915.

- [18] KAYA M. The effects of a new selection operator on the performance of a genetic algorithm [J]. Applied Mathematics & Computation, 2011, 217 (19): 7669-7678.
- [19] 肖婷,汤宝平,秦毅,等. 基于流形学习和最小二乘支持向量机的滚动轴承退化趋势预测[J]. 振动与冲击, 2015,34(9):149-153.
XIAO T, TANG B P, QIN Y, et al. Degradation trend prediction of rolling bearings based on manifold learning and least square support vector machine [J]. Journal of Vibration and Shock, 2015, 34(9): 149-153.
- [20] 李彬,张云,王立平,等. 基于遗传算法优化小波神经网络数控机床热误差建模[J]. 机械工程学报, 2019, 55(21):215-220.
LI B, ZHANG Y, WANG L P, et al. Optimization of thermal error modeling for nc machine tools based on wavelet neural network based on genetic algorithm [J]. Journal of Mechanical Engineering, 2019, 55 (21): 215-220.

作者简介



马健, 2019 年于南昌大学获得学士学位, 现为湖南大学硕士研究生, 主要研究方向为可靠性和电气测量。

E-mail: mj15870050268@163.com

Ma Jian received his B.Sc. degree from Nanchang University in 2019. Now, he is a M.Sc. candidate in Hunan University. His main research interest includes reliability and electrical measurement.



滕召胜(通信作者), 分别于 1995 年和 1998 年在湖南大学获得硕士学位和博士学位, 现为湖南大学教授、博士生导师, 主要研究方向为智能检测与控制系统。

E-mail: tengzs@126.com

Teng Zhaosheng (Corresponding author) received his M.Sc. and Ph.D. degrees both from Hunan University in 1995 and 1998, respectively. He is currently a professor and doctoral supervisor in Hunan University. His main research direction is intelligent detection and control system.