

DOI: 10.19650/j.cnki.cjsi.J2107634

# 基于 OGA-KSVR 的电能计量设备测量误差预测\*

马俊,滕召胜,唐求,邱伟,杨莹莹  
(湖南大学电气与信息工程学院 长沙 410082)

**摘要:**针对多应力条件下电能计量设备测量误差难以预测的问题,提出一种基于核支持向量回归(KSVR)的电能计量设备测量误差预测方法,并提出一种优化遗传算法(OGA)对核参数进行优化。首先,提出一种线性加权多核函数融合多个应力特征,利用核权值系数刻画不同应力对电能计量设备的影响。然后,在核函数参数选择阶段,为了避免对参数人工调整的局限性,提出一种交叉概率与变异概率自适应调整的优化遗传算法,并将其应用到核参数优化选择问题中。国网新疆高干热试验基地智能电表运行数据分析表明,本文所提模型具有较高的准确性,预测结果的平均均方误差为 0.000 18,最高拟合优度可达 0.989,可以为电能计量设备在多环境应力下的健康管理提供针对策略。

**关键词:** 电能计量设备;核支持向量回归;优化遗传算法;健康管理

**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

## Measurement error prediction of power metering equipment based on OGA-KSVR

Ma Jun, Teng Zhaosheng, Tang Qiu, Qiu Wei, Yang Yingying

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

**Abstract:** Aiming at the problem that the measurement error of power metering equipment is difficult to predict under multi-stress conditions, a measurement error prediction method of power metering equipment is proposed based on kernel support vector regression (KSVR), and an Optimized Genetic Algorithm (OGA) is proposed to optimize the kernel parameters. Firstly, a linear weighted multi-kernel function is proposed to fuse multiple stress features, and the kernel weight coefficient is used to describe the influence of different stresses on the power metering equipment. Then, in the parameter selection stage of the kernel function, to avoid the limitation of manual parameter adjustment, an OGA with crossover probability and mutation probability adaptive adjustment is proposed and applied to the optimization selection issue of kernel parameters. The operation data analysis of the smart electricity meters in Xinjiang High Dry Heat Test Base of State Grid shows that the proposed model has high accuracy, the average mean square error of the prediction results is 0.000 18, and the highest goodness of fit can reach 0.989, which can provide a targeted strategy for the health management of power metering equipment under multiple environmental stresses.

**Keywords:** power metering equipment; kernel support vector regression; optimized genetic algorithm; health management

## 0 引言

近年来,随着国家对智能电网建设的推进以及社会生产生活需要,智能电表、电子式互感器、采集终端等一批新型电能计量设备得到了广泛的应用<sup>[1]</sup>。新兴电能计

量设备中包含大量的电子元器件,长期在极限环境下运行势必会影响元器件性能,造成测量误差增加,从而影响计量设备整机的性能<sup>[2]</sup>。电能计量设备在极限环境下的准确性、稳定性是当下讨论研究的热点问题<sup>[3]</sup>。研究计量设备在各种环境因素干扰下的测量误差、变化规律及性能的可靠性,不仅有利于提升国内计量设备的整体制

收稿日期:2021-03-19 Received Date: 2021-03-19

\* 基金项目:国家电网公司总部科技项目(5230HQ19000F)、国家重点研发计划(2019YFF0216800)、湖南省研究生科研创新项目(CX20200426)资助

造水平,提高国内计量设备行业的国际竞争力,而且可以降低计量设备运行和检修的成本,具有巨大的经济价值和社会意义<sup>[4-5]</sup>。

国内外学者针对仪器设备的运行误差预测及可靠性分析问题展开了大量颇有成效的研究。早期的研究主要通过故障树、专家系统等方法对电力设备的运行误差、故障概率进行分析<sup>[6-7]</sup>,实现了对电力设备子系统故障概率的有效计算。然而,对于电能计量设备这一类高集成系统,在实际应用中难以对设备故障原因进行精准定位。近年来,随着计算机技术与人工智能的飞速发展,基于数据驱动的误差预测建模与设备可靠性分析技术得到了广泛的关注。

基于对设备性能评估方式的差异,数据驱动方法可进一步分为概率性方法与确定性方法<sup>[8]</sup>。概率性方法可以有效处理不确定性问题并给出预测结果的概率分布。目前常用概率性方法的有多层贝叶斯网络、维纳退化模型以及比例风险回归模型。如文献[9]提出了一种基于健康指标分析的比例风险回归模型来预测电力设备的故障率;文献[10]构建了一种多层贝叶斯 B 样条模型来实现多应力条件下电能计量设备的可靠性评估。然而,概率性预测方法严重依赖于合适的先验信息<sup>[11]</sup>,否则在多变量预测时容易引入额外信息从而影响预测结果的准确性。

由于不依赖于先验选择,确定性方法已经广泛应用于多元信息融合与设备性能评估领域。常见的方法如人工神经网络、支持向量机等受到了行业越来越多的重视。如文献[12-13]采用人工神经网络对动态电气设备、配电系统进行性能评估与寿命预测。文献[14]采用最小二乘支持向量机比较精确的给出了发动机的剩余寿命预测结果。文献[15]利用最小二乘支持向量机对机械式温度仪表测量误差进行预测,取得了比较高的预测精度。上述人工神经网络与支持向量机方法亦各有不足,人工神经网络虽然具有较高的预测精度,但其对训练样本需求量大<sup>[16]</sup>,在小样本数据条件的电能计量设备测量误差分析中难以取得较高的精度。支持向量机虽然在解决小样本、非线性回归问题中具有明显优势,但目前的研究大多基于单一核函数进行数据映射,无法对多应力输入进行有效融合,且存在核函数参数选择困难的问题<sup>[17]</sup>。

基于此,本文依托国网新疆高干热典型环境试验基地的智能电表现场运行数据,在传统支持向量回归研究的基础上,提出了一种基于核支持向量回归(kernel support vector regression, KSVR)的多应力条件下电能计量设备测量误差预测方法,通过优化遗传算法(optimized genetic algorithm, OGA)实现核参数优化。本文的主要贡献如下:

1) 提出一种 KSVR 模型,克服了传统支持向量回归多特征处理预测精度下降的缺陷,实现了多应力输入下的特征融合;2) 通过 OGA 算法实现对 KSVR 模型核函数的参数选择,提高了电能计量设备测量误差的预测精度;3) 结合新疆高干热环境下智能电表的实际运行数据进行实验分析,验证了本文提出的预测模型的有效性。

## 1 误差数据采集与分析

新疆地区位于我国西北部,气候环境复杂,是我国一个典型的高干热地区。长期运行在这种极端环境条件下的电能计量设备的运行特性必将随着投入使用的增加而发生退化,影响设备的正常工作。通过研究在新疆高干热典型环境下电能计量设备的性能变化情况,分析不同应力对电能计量设备的影响程度,从而可以为该地厂商改进设备质量提供针对性策略。

图 1 显示了新疆高干热地区的电能计量设备数据采集平台。电能计量设备的试验信息先被统一整合到基站,再通过局域网和 GPRS 网络传输将试验信息传递到基站服务器进行后续的数据分析。利用图 1 所示的数据采集系统,随机采集 A、B 两公司的智能电表从 2017 年 12 月到 2020 年 5 月的测量误差数据进行分析,其结果可视化如图 2 所示,其中,点线图表示测量误差变化趋势,柱形图以及色阶表示相应的湿度与温度变化。

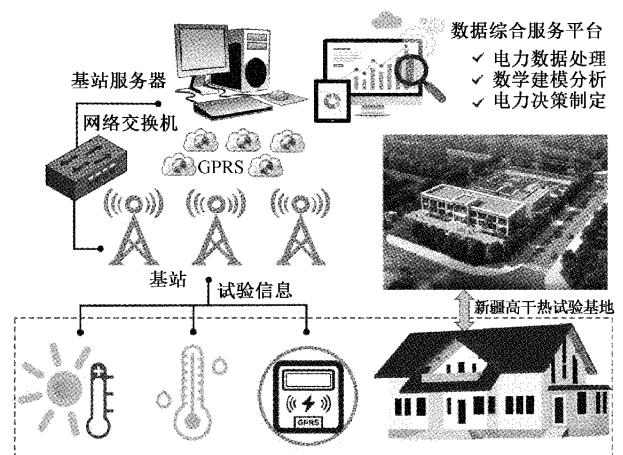


图 1 电能计量设备数据采集系统

Fig. 1 Data acquisition system of power metering equipment

由图 2 可以看出,在新疆地区夏季最高温度可达 47.20℃,最低湿度接近 10% RH。如此的极端环境应力导致智能电表的测量误差在夏季增加尤为明显。为了进一步分析在该极端环境下,电能计量设备的性能变化情况,依据新疆地区的高干热特征,选择温度( $T$ )、湿度( $H$ )以及运行时间( $t$ )作为应力输入,即  $x = \{T, H, t\}$ ,以电能




图2 新疆地区智能电表运行数据

Fig. 2 Operation data of smart electricity meter in Xinjiang region

计量设备的测量误差( $E$ )作为输出  $y = \{E\}$ , 进行退化建模。为了充分融合3种应力特征, 提出KSVR预测模型进行回归分析。

## 2 基于核支持向量回归模型的电能计量设备测量误差预测

### 2.1 核支持向量回归模型

给定一组测量误差与应力特征数据集  $D = \{x_i, y_i\}_n$ ,  $i = 1, 2, \dots, n$ , 其中  $x_i$  表示某组应力输入,  $y_i$  表示相应的测量误差。传统的支持向量回归方法使用单个核函数将特征数据  $D$  映射到一个高维空间。RBF核是支持向量回归中最常用的核函数。对于  $D$  中的两个数据点  $x_i, x_j$ , RBF核函数的定义如下:

$$K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2) \quad (1)$$

式中:  $\gamma > 0$  是RBF核半径, 决定核函数的映射结果。

对于多应力下的测量误差预测, 更多的输入信息有利于提高模型的预测精度。为了充分融合时间、温度以及湿度应力特征, 本文提出一种加权线性多核支持向量回归模型, 模型表达式如下:

$$\begin{cases} K_f = \lambda_1 K_t + \lambda_2 K_T + \lambda_3 K_H \\ \text{s. t. } \lambda_1 + \lambda_2 + \lambda_3 = 1 \end{cases} \quad (2)$$

式中:  $K_t, K_T, K_H$  分别表示时间、温度以及湿度所对应的核函数,  $\lambda_1, \lambda_2, \lambda_3$  是相应的权值系数。

为了学习支持向量回归模型的最优决策平面, 通过引入松弛因子  $\xi^{(*)} = [\xi_1, \xi_1^*, \dots, \xi_n, \xi_n^*] \in R$ , 融合核支持向量回归的优化问题转换为如式(3)所示, 约束条件如式(4)所示。

$$\min_{\omega, b, \xi^{(*)}} \frac{1}{2} \omega^T \omega + \frac{c}{n} \sum_{i=1}^n (\xi_i + \xi_i^*) \quad (3)$$

约束为:

$$\text{s. t. } \begin{cases} (\omega^T \varphi(x_i) + b) - y_i \leq \varepsilon + \xi_i \\ y_i - (\omega^T \varphi(x_i) + b) \leq \varepsilon + \xi_i^* \\ \xi_i, \xi_i^* \geq 0 \end{cases} \quad (4)$$

式中:  $\omega$  和  $b$  分别是决策平面的权值系数与偏置;  $\varphi(\cdot)$  是映射高维特征空间;  $\varepsilon$  是不敏感损失;  $c$  为惩罚系数。

通过引入拉格朗日对偶函数, 利用偏导数即可求解所提回归模型的相关参数。给定新的一组智能电表应力数据( $x'$ ), 融合支持向量回归的决策函数为:

$$y' = \sum_{i=1}^n (\alpha_i^* - \alpha_i) K_j(x_i, x') + b \quad (5)$$

式中:  $\alpha$  表示拉格朗日乘子;  $y'$  为测量误差。

### 2.2 核函数选择与权值参数分析

由式(5)可知, 核函数可以直接影响KSVR的预测结果。因此选择一组合适的核函数至关重要。为验证融合核支持向量回归模型的性能, 随机选取A公司某批次20只智能电表样本进行试验。为了选择一组合适的核函数, 选择目前常用的线性核、多项式核以及高斯核进行比较实验。为了公平比较, 不同应力对应的核参数  $\gamma$  取相同值, 惩罚系数设置为1 000, 以误差预测值与实际值的均方误差(mean squared error, MSE)作为评价标准, 不同核函数组合下的KSVR性能变化如表1所示。

表1 不同核函数组合下的模型性能

Table 1 Model performance under different kernel function combinations

核函数	权值参数			MSE
	$\lambda_1$	$\lambda_2$	$\lambda_3$	
多项式+线性	0	0.5	0.5	0.001 96
多项式+高斯	0	0.5	0.5	0.000 89
高斯+多项式	0	0.5	0.5	0.000 69
高斯+线性	0	0.5	0.5	0.001 52
线性	0.2	0.5	0.3	0.001 77
多项式	0.2	0.5	0.3	0.000 78
高斯	0.2	0.5	0.3	0.000 59
高斯	0.1	0.7	0.2	0.000 43
高斯	<b>0.05</b>	<b>0.8</b>	<b>0.15</b>	<b>0.000 41</b>

由表1可知高斯核与多项式核的整体性能要优于线性核, 多项式核略低于高斯核。如当权值设置相同时高斯核与多项式核的MSE分别为0.000 59和0.000 78。此外, 注意到温度应力应取一个较高的核权值。利用网格搜索法对核权值进一步微调, 最终时间、温度、湿度3组应力的高斯核权值设为0.04、0.82以及0.14。与权

值参数不同,核参数彼此独立,无法用网格搜索有效对3组核参数进行优化,因此需要寻找一种合适的多变量优化方法。

### 2.3 基于优化遗传算法的核参数设置

遗传算法(genetic algorithm, GA)是一种启发式全局随机搜索最优化方法,具有良好的自适应能力和鲁棒性。然而,传统的 GA 在优化求解时采用固定的交叉概率( $P_c$ )和变异概率( $P_m$ ),在多变量寻优时容易收敛于局部最优值。依据本文优化的目标,选取 KSVR 模型预测结果的 MSE 作为 OGA 模型的适应度函数,并基于适应度函数通过引入线性函数与 Sigmoid 函数对交叉概率与变异概率进行自适应调整,调整为:

$$P_c = \begin{cases} P_{c3} + \frac{2(P_{c2} - P_{c3})}{1 + \exp\left(A \frac{2(f_{ave} - f')}{f_{ave} - f_{min} - 1}\right)}, & f' \leq f_{ave} \\ P_{c2} - \frac{(P_{c1} - P_{c2})(f_{ave} - f')}{f_{max} - f_{ave}}, & f' > f_{ave} \end{cases} \quad (6)$$

$$P_m = \begin{cases} P_{m3} + \frac{2(P_{m2} - P_{m3})}{1 + \exp\left(A \frac{2(f_{ave} - f')}{f_{ave} - f_{min} - 1}\right)}, & f \leq f_{ave} \\ P_{m2} - \frac{(P_{m1} - P_{m2})(f_{ave} - f')}{f_{max} - f_{ave}}, & f > f_{ave} \end{cases} \quad (7)$$

式中: $f_{min}$ ,  $f_{ave}$ ,  $f_{max}$  分别表示每一代群体中的最小、平均以及最大适应度值; $f'$ ,  $f$  为所选中的执行交叉和变异操作的亲代中较小的适应度值,满足: $P_{c1} > P_{c2} > P_{c3}$ ,  $P_{m1} > P_{m2} > P_{m3}$ 。

由式(6)和(7)可知:OGA 的自适应调整策略为,在种群进化早期( $f > f_{ave}$ ),选用线性函数控制交叉(变异)概率等比例下降,使得较差个体可以拥有一定的交叉与变异概率值,有利于保持种群的多样性,避免参数搜索结果陷入局部最优;在种群进化后期( $f < f_{ave}$ ),通过 Sigmoid 函数拉低靠近最小适应度的概率值,从而尽可能的保存优秀个体,提高参数优化的准确度。

基于 OGA 的核参数优化步骤如下:

1) 初始化种群,设置种群规模为 50,迭代次数 100,核参数范围  $\gamma_t, \gamma_r, \gamma_H$  设为 (1, 10), 交叉概率  $P_{c1}, P_{c2}, P_{c3}$  分别设置为 0.9、0.6 和 0.3, 变异概率  $P_{m1}, P_{m2}, P_{m3}$  分别设置为 0.1、0.05 以及 0.01, 采用实数编码方式对种群编码;

2) 以 KSVR 模型预测结果的 MSE 作为适应度函数,计算初始种群适应度最大、最小以及平均值并记录最小适应度值所在位置;

3) 采用精英保留与锦标赛规则产生新个体,依据

式(6)和(7)自动调整交叉与变异概率,执行交叉与变异操作,产生子种群;

4) 重复步骤 2) 和 3), 将种群中的最小适应度值作为最优解,当最小适应度值收敛或迭代结束时算法终止,输出最优解以及其所在种群的位置。

为了验证本文所提出的 OGA 的有效性,对比了标准 GA 的核参数寻优结果。其中,对 GA 的交叉概率设置为固定值 0.7, 变异概率设置为 0.01<sup>[17]</sup>, 为了进行公平的比较,标准 GA 的其他参数设置都与 OGA 参数保持一致,两种优化算法的核参数具体寻优结果可视化如图 3 所示。




图3 OGA 与 GA 寻优结果对比

Fig. 3 The optimization result comparison of OGA and GA

由图 3 可以看出,传统的 GA 由于采用固定的交叉概率与变异概率值,其参数优化结果比较早地收敛到某个局部最优值,其最优解为 0.000 33。相比之下,自适应调整交叉概率与变异概率的 OGA 所寻优的最佳适应度值即 MSE 为 0.000 21, 预测精度提高了 0.000 12, 实验结果表明,通过自适应地调整交叉概率与变异概率值,OGA 能够找到一组更为精确的核参数组合。此时,所对应的各个应力的核参数  $\gamma_t, \gamma_r, \gamma_H$  的最优组合为: (1.14, 9.93, 1.05)。

### 2.4 多应力环境下电能计量设备测量误差预测框架

结合所提的 OGA 和 KSVR 方法,本节进一步提出多应力环境下电能计量设备的测量误差预测框架 OGA-KSVR 用于典型环境下计量设备的性能评估与健康管理,具体的描述如下:

1) 基于 KSVR 的测量误差预测建模:通过对不同应力分配各自相应的核函数与权值,实现对多个应力因子的有效融合,提高预测模型的泛化能力;

2) 基于 OGA 算法的核参数优化:通过式(6)和(7)调整交叉概率与变异概率优化遗传算法,进而实现对 KSVR 模型中核参数的自适应优化设置;

3) 测量误差预测与性能评估:输入新的应力数据实现多应力环境下对电能计量设备的测量误差预测,利用



均方误差 MSE 与决定系数 R2 评估模型性能;

4) 多应力下的电能计量设备健康管理:基于 OGA-KSVR 的预测结果,分析不同公司电能计量设备在多应力环境下的适应性能,找出影响计量设备性能变化的关键应力因子,为设备升级提供指导策略。

### 3 实验验证

#### 3.1 原始测量误差数据处理

为了进一步验证本文所提算法的准确性,通过与国网新疆高干热典型环境实验室合作,随机抽取新疆地区 A、B 两家电能计量设备公司某批次的智能电表样本各 20 只,样本运行数据的记录时间从 2017 年 12 月到 2020 年 5 月,所有数据均为按月独立抽取,每个样本共计 30 个月的数据点,图 4 显示了新疆典型高干热地区智能电表运行现场试验图,集中器用来整合各个智能电表的运行状态数据。在后续的比较实验中,两个公司的训练样本与测试样本均按照 3:1 的比例分配,即训练样本各 15 只,测试样本各 5 只。实验采用 libSVM 包作为 KSVR 建模工具,以 MATLAB 作为实验仿真环境。




图 4 新疆智能电能表现场运行试验

Fig. 4 Field operation experiment of Xinjiang smart electricity meters

图 5、6 分别显示了 A、B 公司各 20 只智能电表的测量误差变化图。可以看出, A、B 公司的测量误差随时间应力呈现出周期性缓慢递增趋势,表明在新疆地区,智能电表测量误差受环境应力的影响明显高于时间应力。此外,可以看出 A 公司智能电表整体差异性比较大, B 公司差异性较小,但总体测量误差 B 公司要高于 A 公司,表明 A 公司的智能电表在新疆地区的适应性更高。




图 5 A 公司智能电表原始测量误差数据

Fig. 5 Raw measurement error data of company A's smart electricity meter




图 6 B 公司智能电表原始测量误差数据

Fig. 6 Raw measurement error data of company B's smart electricity meter

#### 3.2 各模型预测结果对比

为了验证本文模型的准确性和有效性,分别选取 A、B 公司训练样本对所提模型进行训练,同时对比了目前比较常用的两种数据驱动预测方法,包括人工神经网络<sup>[18]</sup>(模型一)以及多层次贝叶斯模型<sup>[19]</sup>(模型二)。为了公平的比较,所有模型的训练过程中都采用五折交叉验证的方法设置模型参数。A、B 两公司的电能计量设备测量误差在测试集的预测结果如图 7、8 所示。




图 7 A 公司不同模型预测曲线

Fig. 7 Prediction curve of different models for company A




图8 B公司不同模型预测曲线

Fig. 8 Prediction curve of different models for company B

由图7、8可以看出,3种预测模型皆可追踪数据的变化趋势,但 OGA-KSVR 更趋近于真实的误差数据,表明所提模型能有效融合环境应力对测量误差的影响,从而获得更为精确的预测结果。为了更为直观的比较各个模型的预测性能,分别求取了不同模型预测结果的 MSE 与  $R^2$ ,如表2所示。

表2 不同模型 MSE 与  $R^2$  对比结果Table 2 Comparison results of the MSE and  $R^2$  for different models

模型	A 公司		B 公司	
	MSE	$R^2$	MSE	$R^2$
模型一	0.001 52	0.821	0.000 92	0.951
模型二	0.000 76	0.865	0.000 73	0.968
本文模型	<b>0.000 21</b>	<b>0.896</b>	<b>0.000 14</b>	<b>0.989</b>

由表2可以看出,本文所提的 OGA-KSVR 预测模型在 A、B 两公司的预测效果均优于其余模型。以 B 公司为例进行具体说明,模型一与模型二预测结果的 MSE 分别为 0.000 92 和 0.000 73,本文模型预测结果的 MSE 为 0.000 14,表明融合核函数可以充分利用特征信息,从而减少预测误差。此外,模型一与模型二预测结果的  $R^2$  分别为 0.951 和 0.968,本文模型可达 0.989,进一步验证了本文模型的有效性。

### 3.3 健康管理应用

为了定量分析不同环境应力对智能电表的影响程度,结合网格搜索方法,将 A、B 两公司 OGA-KSVR 模型中各个应力核函数所占的权值比重进行整合,其结果如表3所示。

表3 不同应力的核函数权值

Table 3 The kernel function weights for different stresses

应力	权值	
	A 公司	B 公司
时间	0.04	0.05
温度	0.82	0.80
湿度	0.14	0.15

由表3可知,在 A、B 两公司中,温度应力与湿度应力的权值系数均高于时间应力。A、B 公司中的温度应力权值分别为 0.82 与 0.80,湿度应力权值为 0.14 与 0.15,而时间应力的权值仅为 0.04 与 0.05。实验结果表明,在新疆高干热环境下,环境应力对智能电表的影响程度明显强于时间应力。此外,温度应力的权值明显高于湿度应力,表明在该地区温度应力是影响智能电表健康状态的主要因素,在后续的电能计量设备更新换代中,应着重增强设备的温度适应性从而减少电能测量误差进而提高设备的可靠性。

## 4 结 论

为解决多环境应力下电能计量设备测量误差难以预测的问题,本文提出了一种基于 OGA-KSVR 模型的电能计量设备测量误差预测方法。通过赋予核函数不同的权重,从而实现多环境应力的有效融合。在核参数选择阶段,本文提出的优化遗传算法,可以实现多个核参数的优化设置。依托不同计量公司在典型高干热环境下的运行数据进行实验,不同模型的对比实验结果表明,本文所提的 OGA-KSVR 模型具有更为准确的预测性能。依据本文的研究成果,可以为新疆高干热环境下电能计量设备的健康管理提供指导策略,从而帮助计量公司研制出更具适应性的设备,提高经济与社会效益。在本文研究的基础上,后续研究可以建立多应力环境下电能计量设备的退化模型,预测电能计量设备的剩余使用寿命,为我国后续对不同典型环境地区即将开展的计量设备检定标准验证与更新提供指导。

### 参考文献

- [1] 陈奎,赵伟,肖勇,等.非整周期采样条件下有功电能计量的新算法[J].仪器仪表学报,2017,38(4):861-869.  
CHEN L, ZHAO W, XIAO Y, et al. New active electric energy measurement algorithm under non-integer-period sampling[J]. Chinese Journal of Scientific Instrument, 2017, 38(4): 861-869.
- [2] 向世强,唐求,宋鹏,等.非线性负荷电能计量方法研究[J].电子测量与仪器学报,2018,32(4):181-186.  
XIANG SH Q, TANG Q, SONG P, et al. Research on nonlinear load energy measurement method[J]. Journal of Electronic Measurement and Instrumentation, 2018, 32(4): 181-186.
- [3] QIU W, TANG Q, YAO W, et al. Probability analysis

- for failure assessment of electric energy metering equipments under multiple extreme stresses [J]. *IEEE Transactions on Industrial Informatics*, 2021, 17(6): 3762-3771.
- [4] 胡江溢, 祝恩国, 杜新纲, 等. 用电信息采集系统应用现状及发展趋势[J]. *电力系统自动化*, 2014, 38(2): 131-135.
- HU J Y, ZHU EN G, DU X G, et al. Application status and development trend of power consumption information collection system [J]. *Electric Power Automation Equipment*, 2014, 38(2): 131-135.
- [5] 刘旭明, 唐求, 邱伟, 等. 基于 ZINB 层次贝叶斯智能电能表的可靠性预估[J]. *电子测量与仪器学报*, 2019, 33(7): 28-36.
- LIU X M, TANG Q, QIU W, et al. Reliability evaluation and prediction of smart meters based on ZINB hierarchical Bayesian [J]. *Journal of Electronic Measurement and Instrumentation*, 2019, 33(7): 28-36.
- [6] 李练兵, 张秀云, 王志华, 等. 故障树和 BAM 神经网络在光伏并网故障诊断中的应用[J]. *电工技术学报*, 2015, 30(2): 248-254.
- LI L B, ZHANG X Y, WANG ZH H, et al. Fault diagnosis in solar photovoltaic grid-connected power system based on fault tree and BAM neural network[J]. *Transactions of China Electrotechnical Society*, 2015, 30(2): 248-254.
- [7] HIRAOKA Y, MURSKAMI T, YAMAMOTO K, et al. Method of computer-aided fault tree analysis for high-reliable and safety design [J]. *IEEE Transactions on Reliability*, 2016, 65(2): 687-703.
- [8] CAI B, HUANG L, XIE M. Bayesian networks in fault diagnosis [J]. *IEEE Transactions on Industrial Informatics*, 2017, 13(5): 2227-2240.
- [9] QIU J, WANG H, LIN D, et al. Nonparametric regression-based failure rate model for electric power equipment using lifecycle data[J]. *IEEE Transactions on Smart Grid*, 2015, 6(2): 955-964.
- [10] 邱伟, 唐求, 刘旭明, 等. 基于 MBBS 的电能计量设备故障率预估[J]. *仪器仪表学报*, 2019, 40(1): 43-51.
- QIU W, TANG Q, LIU X M, et al. Failure rate estimation of power metering equipment based on multilayered Bayesian B-spline method [J]. *Chinese Journal of Scientific Instrument*, 2019, 40(1): 43-51.
- [11] 张玉杰, 冯伟童, 刘大同, 等. 基于贝叶斯更新的机电作动器健康因子构建方法[J]. *仪器仪表学报*, 2019, 40(5): 124-131.
- ZHANG Y J, FENG W T, LIU D T, et al. Health indicator construction method based on Bayesian updating for electro-mechanical actuator [J]. *Chinese Journal of Scientific Instrument*, 2019, 40(5): 124-131.
- [12] ZHUKOVSKIY YU L, KOROLEV N A, BABANOVA I S, et al. The prediction of the residual life of electromechanical equipment based on the artificial neural network [J]. *IOP Conference Series: Earth and Environmental Science*, 2017: 032056.
- [13] 戴志辉, 李芷筠, 焦彦军, 等. 基于 BP 神经网络的小样本失效数据下继电保护可靠性评估[J]. *电力自动化设备*, 2014, 34(11): 129-134.
- DAI ZH H, LI ZH J, JIAO Y J, et al. Reliability assessment based on BP neural network for relay protection system with a few failure data samples [J]. *Electric Power Automation Equipment*, 2014, 34(11): 129-134.
- [14] 马小骏, 任淑红, 左洪福, 等. 基于 LS-SVM 算法和性能可靠性的航空发动机在翼寿命预测方法[J]. *交通运输工程学报*, 2015, 15(3): 92-100.
- MA X J, REN SH H, ZUO H F, et al. Prediction method of aero-engine life on wing based on LS-SVM algorithm and performance reliability [J]. *Journal of Traffic and Transportation Engineering*, 2015, 15(3): 92-100.
- [15] 叶永伟, 陆俊杰, 钱志勤, 等. 基于 LS-SVM 的机械式温度仪表误差预测研究[J]. *仪器仪表学报*, 2016, 37(1): 57-66.
- YE Y W, LU J J, QIAN ZH Q, et al. Research on error prediction of mechanical temperature meter based on LS-SVM [J]. *Chinese Journal of Scientific Instrument*, 2016, 37(1): 57-66.
- [16] SHU Y F, WEI X CH, YANG R, et al. An equivalent dipole model hybrid with artificial neural network for electromagnetic interference prediction [J]. *IEEE Transactions on Microwave Theory and Techniques*, 2019, 67(5): 1790-1797.
- [17] 邓聪颖, 冯义, 魏博, 等. 基于 SVR-GA 算法的广义加工空间机床切削稳定性预测与优化研究[J]. *仪器*

仪表学报, 2019, 40(10): 227-236.

DENG C Y, FENG Y, WEI B, et al. Research on the prediction and optimization of machine tool cutting stability in generalized manufacturing space based on support vector regression machine and genetic algorithm[J]. Chinese Journal of Scientific Instrument, 2019, 40(10): 227-236.

- [18] 金阳忻. 基于模糊神经网络的电能表误差超风险预测模型[J]. 电网技术, 2019, 43(6): 1962-1968.

JIN Y X. Electricity meter error outlier risk prediction model based on fuzzy neural network [J]. Grid Technology, 2019, 43(6): 1962-1968.

- [19] 杜蜀薇, 成达, 邱伟, 等. 基于分层贝叶斯的电能表短期故障评估与预测[J]. 电子测量与仪器学报, 2018, 32(12): 178-184.

DU SH W, CHENG D, QIU W, et al. Evaluation and prediction of short-term failure of electric energy meter based on hierarchical Bayes [J]. Journal of Electronic Measurement and Instrumentation, 2018, 32(12): 178-184.

## 作者简介



马俊, 2019 年于湖南大学获得学士学位, 现为湖南大学博士研究生, 主要研究方向为可靠性分析和电能质量检测。

E-mail: 19090277@hnu.edu.cn

**Ma Jun** received his B.Sc. degree from Hunan University in 2019. Now, he is a Ph.D. candidate in Hunan University. His main research interest includes reliability analysis and electric energy quality test.



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 interest includes intelligent detection and control systems.