

DOI: 10.19650/j.cnki.cjsi.J2107358

基于 CK-GPR 的多应力环境智能电表剩余寿命预测*

段俊峰¹, 李 宁², 唐 求¹, 张 伟², 滕召胜¹

(1. 湖南大学电气与信息工程学院 长沙 410082; 2. 国网新疆电力有限公司营销服务中心 乌鲁木齐 830011)

摘 要:针对智能电表科学定期更换需求,建立一种基于智能电表基本误差数据的剩余寿命(RUL)预测方法。首先采用 Person 相关系数筛选对智能电表基本误差数据影响较大的环境应力作为模型输入;然后采用高斯核、Matern32 核及周期核匹配多应力环境下智能电表基本误差趋势;利用贝叶斯方法和蒙特卡洛马尔科夫链(MCMC)求解模型。实验结果表明,不同公司智能电表具有不同环境耐受性,在高干热典型环境条件下,A 公司智能电表数据后验上四分位线达到阈值,剩余寿命为 43 个月;B 公司智能电表未出现普遍失效情况,但未来 47 个月会有较大可能失效,应着手进行故障排查和误差检定工作。在高干热典型环境下智能电表加速超差失效现象不符合计量规程规定的 8 年检定周期,应动态调整周期检定工作。

关键词:智能电表;剩余寿命预测;高斯过程;组合核函数;回归方法

中图分类号: TM933.4 TH17 文献标识码: A 国家标准学科分类代码: 460.40 470.40

Remaining useful life prediction of smart meter based on CK-GPR in multi-stress environment

Duan Junfeng¹, Li Ning², Tang Qiu¹, Zhang Wei², Teng Zhaosheng¹

(1. College of Electrical and Information Engineering, Hunan University, Changsha 410082, China;
2. Marketing Service Center, State Grid Xinjiang Electric Power Co., Ltd., Urumqi 830011, China)

Abstract: Aiming at the demand for scientific periodic replace of smart meters, a remaining useful life (RUL) prediction method based on the basic error data of smart meters is established. Firstly, the Person correlation coefficient is adopted to screen out the environmental stress that has great impact on the basic error data of the smart meter as the model input; then the Gaussian kernel, the Matern32 kernel, and the periodic kernel are adopted to match the basic error trend of the smart meter under the multi-stress environment; the Bayesian method and the Monte Carlo Markov Chain (MCMC) are used to solve the model. Experiment results show that smart meters from different companies have different environmental tolerances. Under typical environmental condition of high dry heat, the posterior upper quartile value of the smart meters from A company reaches the threshold, and the RUL is 43 months; the smart meters from company B has no general failures happened, however there will be a great possibility to failure in the next 47 months, and troubleshooting and error verification should be started. In the typical environment of high dry heat, the accelerated out-of-tolerance failure phenomenon of smart meters does not meet the 8-year verification period stipulated in the measurement regulations, and the periodic verification work should be dynamically adjusted.

Keywords: smart meter; remaining useful life prediction; Gaussian process; combined kernel function; regression method

0 引 言

智能电表作为智能电网的终端设备,其可靠运行对电网稳定、经济运行起着至关重要的作用^[1],也关乎所有

工商用户、居民用户的收费公正与用电安全^[2]。我国自 2009 年推广应用智能电表以来,在网运行智能电表已达 5.7 亿只。国网公司对智能电表设计寿命要求大于 10 年,而国标 JJG 596-2012《电子式交流电能表检定规程》规定的检定周期为 8 年^[3],意味着绝大部分计量准确度

收稿日期:2021-01-09 Received Date: 2021-01-09

* 基金项目:国家自然科学基金(52077067)、国家重点研发计划(2019YFF0216800)、湖南省研究生科研创新项目(CX20200426)资助

合格、功能正常的智能电表只能提前报废,每年因此将损失上百亿元。为此,基于智能电表基本误差开展智能电表的可靠性评估、寿命预测,为科学轮换提供理论依据,具有巨大经济价值与重要的社会意义。

国内外学者针对仪器设备的剩余寿命(remaining useful life, RUL)预测问题进行了大量研究。目前剩余寿命方法主要分为机理建模和数据驱动方法两大类。早期产品寿命较短,借助寿命试验、加速寿命试验可得到足够多的产品失效数据并据此开展寿命预测和可靠性评估^[4]。然而这些模型针对电子元器件的可靠性评估并不能满足用户对产品高可靠性的需求,且Eyring模型、Arrhenius等加速应力模型并不适用组件级以上的加速试验^[5]。随着传感器技术与信号处理技术的发展,基于数据驱动的寿命预测方法已逐渐成为主流^[6-7]。数据驱动方法泛指无需精确机理,以设备相关监测数据对设备进行预警和管理的方法。其主要借助人工智能算法对设备退化数据建模,常用的时间序列分析算法有自回归滑动模型、支持向量机、人工神经网络及其组合方法,但这些模型需要大量数据训练模型,且其结果得到的是RUL的大小而非分布,不能很好地反映预测结果的不确定性^[8]。基于随机过程的退化模型被广泛用于描述性能退化建模并能给出RUL的区间分布结果,得到越来越多的关注与认可^[9]。当前最常用的随机过程建模方法是Wiener过程。它通过逆高斯过程得到性能退化的寿命分布,如文献[10]通过加速试验数据和外场数据对智能电表进行了RUL计算,但Wiener过程计算复杂,实现代价较大。

为解决人工智能算法对大量数据的依赖以及不能给出预测结果概率区间的缺陷,并保留随机过程建模的优势。高斯过程回归(Gaussian process regression, GPR)算法作为另一种方兴未艾的随机过程算法,具有严格的理论统计学基础,可以很好地解决数据中存在的高维数、小样本、高度非线性等复杂回归问题,且其自身具有很强的泛化能力^[11]。文献[12]在高斯过程中实现了电力系统饱和负荷预测;文献[13]构建了锂电池健康因子并基于GPR模型进行了剩余寿命间接预测。但上述研究未有将现场环境条件与仪器性能特征相结合开展高斯过程回归预测。

智能电表是现场安装性仪器仪表,不可避免地受温度、湿度、气压、盐雾、紫外线等多种环境应力的作用,不能仅基于一种环境应力参数开展其实际可靠性评价与寿命预测。据此,本文依据国网公司新疆吐鲁番试验基地的智能电表现场实验数据,在GPR模型架构上,建立一种组合核高斯过程回归方法(combined kernel gaussian process regression, CK-GPR)进行多种环境应力作用下的智能电表剩余寿命预测。高斯过程回归模型是非参数非

线性回归模型,不仅可获得数据点预测值,还可得到相应置信区间预测值;通过组合不同符合数据特征的核函数改进高斯过程预测效果,进一步基于改进后的高斯过程回归方法实现不同智能电表实际运行数据带置信区间的回归预测,采用MCMC求解出CK-GPR模型中的超参数后验分布;依据后验轨迹首次达阈值的关系,对智能电表剩余寿命进行预测。最后基于现场运行数据、利用软件库PyMC3验证本文方法的准确性。

1 多环境应力下的智能电表退化指标选取

1.1 退化指标的选择依据

新疆高干热环境试验基地位于吐鲁番,年平均温度 17°C ,5~8月平均温度 40°C 左右,地表温度高达 70°C 以上,年最大相对湿度高达100%RH,寒暑差异悬殊,气候环境复杂。长期运行在这种复杂极端条件下的智能电表各部件绝缘强度与运行特性必将随着投入使用时间的增加而向失效方向变化,最终导致故障或超出规定指标情况的发生。

基本误差超差是智能电表失效的重要指标,本文选取基本误差作为智能电表寿命的指标。受环境影响,智能电表运行特性会表现出在一定范围内随机波动的现象。单相、三相智能电表元器件与零部件分别多达200、400个以上,多种环境因素共同影响下,复杂的内部结构必然导致难以分辨表计系统的确切故障起因^[14-15],但会表现出指标性的变动与超差。因此,选取智能电表基本误差作为智能电表的性能退化指标^[16]是可行且合理的。

1.2 退化指标与环境应力热力图

为充分研究智能电表在典型环境应力下的使用寿命,本文选用投放在新疆吐鲁番地区来自不同公司的智能电表运行数据集 D ,包括智能电表的基本误差(Be)、温度(Te)、湿度(RH)、大气压强(hPa)、风速(Wv)等数据。

其中,由于数据采集误差、设备故障等因素,数据集可能会出现数据缺失或异常值情况。必须对数据集进行数据清洗与空值插补。在得到不含空值的数据集后,对上述基本误差与典型环境应力{温度,湿度,气压,风速}进行数据归一化和Person相关性分析,以此相关性作为基本误差受典型环境的影响程度。

在使用距离度量相似性时,不同于线性变换后得到的数据协方差产生了倍值缩放, z -score归一化方式对数据方差进行了归一化,可消除不同维度量纲对距离计算产生的影响;Person积矩相关系数是一个不受任意变量线性变换的无量纲指标^[17-18]。据此做出的智能电表基本误差与高干热环境应力热力图矩阵如图1所示。

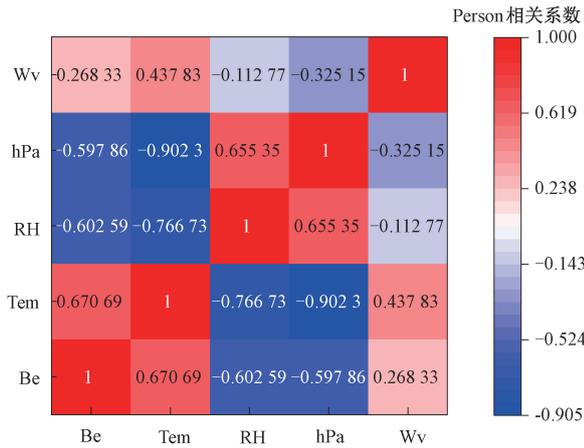


图1 基本误差与“高干热”环境应力相关系数热力图
Fig. 1 Correlation coefficient heat diagram of basic error and “high heat and dry” environmental factors

如图1所示,基本误差与温度相关性最高为0.671,与湿度压强相关性均为0.603,而与风速相关性0.268最弱,同时又有气压与温度相关性0.902。由于运行时间 t 越长,智能电表的失效可能性越大,所以运行时间 t 也是影响寿命的应力。因此在选择基本误差的影响应力时,选择 $\{t, Te, RH\}$ 作为影响智能电表在高干热典型环境下的影响应力,并对数据集的数据进行归一化处理,以消除量纲不同所带来的影响。

2 高斯过程回归模型的智能电表寿命推理

2.1 高斯过程原理

高斯过程(gaussian process, GP)是多元高斯分布向无限维的拓展,其定义是一系列随机变量的集合,且该集合下任意有限个随机变量都有一个联合高斯分布,它是高斯分布的一种自然推广,即关于函数变量的分布^[11]。

设定 $x = \{t, Te, RH\}$ 为影响智能电表误差的应力变量组成的向量,表征时间 t 、环境应力 Te 与 RH 对智能电表运行特性的影响。在函数空间视角下,GP模型假设 $f(X)$ 是一个高斯过程,且该函数 $f(X)$ 完全由其均值函数 $m(X)$ 和协方差函数 $k(X, X')$ 来指定,定义如下:

$$\begin{cases} f(X) \sim \mathcal{GP}(m(X), K(X, X')) \\ m(X) = E(f(X)) \end{cases} \quad (1)$$

式中: $m(X)$ 为高斯过程均值函数,一般为0; $k(X, X')$ 为高斯过程协方差函数。 $X \in R_d$ 为 d 维随机变量。

在实际观测数据中,由于测量设备的误差等因素通常测量结果中含有噪声。假设所含噪声为方差是高斯白噪声 ε 。要预测的智能电表基本误差 $y(X)$ 是定义在运行时间 t 和环境应力组成的向量 X 的输出,所以此时智能电表高斯过程数据测量列可以描述为:

$$\{X, y = f(X) + \varepsilon\} \quad (2)$$

其中,

$$\varepsilon \sim N(0, \delta_n^2) \quad (3)$$

式中: ε 与 $y(X)$ 相互独立,叠加噪声后的数据列仍然服从高斯分布,因此由 n 个 y 组成的观测值集合依然构成一个高斯过程,满足高斯过程的观测值 y 的概率分布,即:

$$y \sim \mathcal{GP}(0, K(X, X') + \delta_n^2 I) \quad (4)$$

2.2 基于组合核高斯过程的智能电表基本误差预测

在高斯过程建模过程中,核函数的不同形式对预测结果起着关键作用,选择合适的核函数是高斯过程建模的重要步骤。在实际应用过程中,应根据训练数据的特征进行合理选择。受环境和自身退化特性的影响,智能电表基本误差的退化呈现出非线性特性,单一核难以描述其真实退化规律。

核函数用于根据 X 值中的距离对预测输出 y 值之间的耦合进行编码。常用的核函数为高斯核函数来保证待学习函数的光滑性,以及使用Matern32核函数来处理局部不规则的数据。两种核公式分别为:

$$k_{se}(X, X') = \exp\left(-\frac{(X - X')^2}{2l_{se}^2}\right) \quad (5)$$

$$k_{MA}(X, X') = \left(1 + \frac{\sqrt{3}(X - X')^2}{l_{ma}}\right) \exp\left(-\frac{\sqrt{3}(X - X')^2}{l_{ma}}\right) \quad (6)$$

若待近似函数可能具有周期性,则可以用周期核函数来适应具有周期性先验知识的数据。选取周期核函数:

$$k_{pe}(X, X') = \exp\left(-\frac{2\sin^2\left(\pi \left| \frac{X - X'}{p} \right| \right)}{l_{pe}^2}\right) \quad (7)$$

为充分刻画多维应力对基本误差造成的影响,本文基于先验知识组合上述核函数,该高斯过程组合核函数的表达式为:

$$f(X) \sim \mathcal{GP}(m(X), \eta_{se}^2 \times k_{se} + \eta_{pe}^2 \times k_{pe} * k_{MA}) \quad (8)$$

式中: η_{se} 与 η_{pe} 为控制幅度变化的超参数。

相比传统单一的高斯核,组合核形式^[19]更加多样、可针对性描述不同应力的特征。高斯核函数由 l_{se} 控制样本距离相关性,可描述基本误差退化数据随时间应力 t 的长期平稳上升趋势;Matern32核函数作为高斯核函数的变体,可反映多特征长度下的样本距离相关性,将其与周期核函数的积描述基本误差受温湿度应力影响的不规则周期性变化。

据此,问题可描述为根据给定数据集 D ,预测出在新的叠加应力组合输入 X_* 下所得到的智能电表基本误差输出 y_* ,即通过归纳法得到可以进行预测的函数关系 Y_* :

$$\begin{pmatrix} y \\ y_* \end{pmatrix} \sim N\left(m(\mathbf{X}), \begin{bmatrix} K(\mathbf{X}, \mathbf{X}') + \delta_n^2 I & K(\mathbf{X}, \mathbf{X}_*) \\ K(\mathbf{X}, \mathbf{X}_*) & K(\mathbf{X}_*, \mathbf{X}_*) \end{bmatrix}\right) \quad (9)$$

式中: $K(\mathbf{X}, \mathbf{X}_*)$ 是测试数据与训练数据的协方差, $K(\mathbf{X}_*, \mathbf{X}_*)$ 是测试数据自身协方差。

由上得到预测值 y_* 的后验分布:

$$y_* | \mathbf{X}, y, \mathbf{X}_* \sim N(\overline{y_*}, \text{cov}(y_*)) \quad (10)$$

其中,

$$\overline{y_*} = K(\mathbf{X}_*, \mathbf{X}) [K(\mathbf{X}, \mathbf{X}') + \delta_n^2 I]^{-1} y \quad (11)$$

$$\text{cov}(y_*) = k(\mathbf{X}_*, \mathbf{X}_*) - K(\mathbf{X}_*, \mathbf{X}) \times$$

$$[K(\mathbf{X}, \mathbf{X}') + \delta_n^2 I]^{-1} K(\mathbf{X}, \mathbf{X}_*) \quad (12)$$

式中: y_* 是测试数据 \mathbf{X}_* 对应预测值 y_* 的均值; $\text{cov}(y_*)$ 是其方差。GP 能给出预测数据的概率分布, 并得到一定置信度的区间预测。在置信度 $1-\alpha$ 下, 会预测出置信区间如下的概率性结果:

$$[l, h] = [\hat{\mu}_* - z_{\frac{\alpha}{2}} \hat{\delta}_{y_*}^2, \hat{\mu}_* + z_{\frac{\alpha}{2}} \hat{\delta}_{y_*}^2] \quad (13)$$

式中: l, h 分别表示预测值的置信下界与置信上界; $z_{\alpha/2}$ 表示标准高斯分布的 α 分位点。

2.3 基于贝叶斯估计的模型先验参数设置

为实现对智能电表剩余寿命的预测, 使用贝叶斯推理, 充分利用早期对事件的认知量并结合已知的观测信息, 不断通过新增数据信息, 以实现和基本误差的充分估计^[20]。

贝叶斯框架下, 首先需确定超参数的先验分布。一般采取超参数先验分布与样本分布共轭方法以达到便于计算后验分布的目的, 但这种方式不足以反映超参数先验信息的多样性。由核函数需满足 Mercer 定理, 对于核函数的幅度超参数 η_i , 以及噪声项 δ 使用半柯西分布保证其正定性; 特征长度尺度超参数 l_i 对应不同核函数的平滑程度, 使用信息量丰富的伽马函数; 而对周期 p , 可由数据特征观测出均值范围, 故使用正态分布。核函数先验设置如下:

$$\begin{cases} \eta_i \sim \text{HalfCauchy}(\nu_i) \\ l_i \sim \text{Gamma}(\alpha_i, \beta_i) \\ p \sim \text{Normal}(\mu, \sigma^2) \\ \delta \sim \text{HalfCauchy}(\nu) \end{cases} \quad (14)$$

$$\Pr(\theta | y) \propto \prod_{i=1}^N \underbrace{\Pr(y_i | \theta)}_{\text{似然函数}} \underbrace{\Pr(\theta)}_{\text{先验分布}} \quad (15)$$

$$\Pr(y_* | y) = \int \underbrace{\Pr(y_* | \theta)}_{\text{似然函数}} \underbrace{\Pr(\theta | y)}_{\text{后验分布}} d\theta \quad (16)$$

式中: $\theta = \{ p, \eta_{se}, l_{se}, l_{pe}, \eta_{pe}, l_{ma}, \delta \}$ 为包含高斯过程组合核所有超参数的向量。

在智能电表退化过程中, 一旦基本误差超过给定的阈值(按照 JIG 596-2012 设定该值为 $\pm 0.6\%$), 则认为该

时间对应的智能电表失效, 也即寿命终止。所以智能电表的寿命可以定义为:

$$T = \inf \{ t: y_* > \omega_{\text{upper}} \mid y_* < \omega_{\text{lower}} \} \quad (17)$$

式中: ω_{upper} 是智能电表失效阈值上限+0.6%; ω_{lower} 是智能电表失效阈值下限-0.6%。

2.4 智能电表寿命预测算法框架

智能电表的基本误差受典型环境影响, 具有加速失效的趋势及跟随环境周期性变化的特点。将数据集视为周期项、趋势项和噪声项的集合, 并分别对应 3 个独立的 GP 组件。先使用边缘 GP, 再采用边缘似然方法来指定边缘后验。采用 MCMC 抽样方法求解模型, 需建立马尔科夫链过程, 鉴于无掉头采样器 (no-u-turn sampler, NUTS) 对高维、冗长数据收敛速度快, 可避免步长对抽样健壮性的影响, 且收敛速度快于 Gibbs 等抽样方法^[21], 本文采用 NUTS 算法对模型进行抽样。

为验证 CK-GPR 模型对智能电表基本误差数据预测的准确性, 在指定先验分布中的参数后, 对似然函数进行抽样, 并依据参数的后验均值不断调整本模型的先验参数, 实现本模型对智能电表基本误差数据的拟合。最终求解出高斯过程超参数后验分布, 并分别预测相应公司的智能电表产品的基本误差何时达到阈值。

智能电表剩余寿命预测流程图如图 2 所示。步骤如下:

- 1) 数据预处理: 对不同公司智能电表产品的历史数据进行重复值及空值检测, 删重补空, 对时间以及各典型环境应力进行按月采样, 数据归一化处理以及相关分析;
- 2) 组合核高斯过程回归模型: 依据处理后的数据特征, 组合核函数, 给定先验分布描述产品关键性能参数真实退化规律;
- 3) CK-GPR 模型求解: NUTS 采样判断模型是否收敛, 不收敛则调整先验分布参数, 收敛则 MCMC 求解;
- 4) 剩余寿命预测: 给定新的时间及环境应力数据输入, 利用更新后的 CK-GPR 模型进行贝叶斯推理得到产品退化轨迹的后验预测; 设定失效阈值, 计算剩余寿命分布。

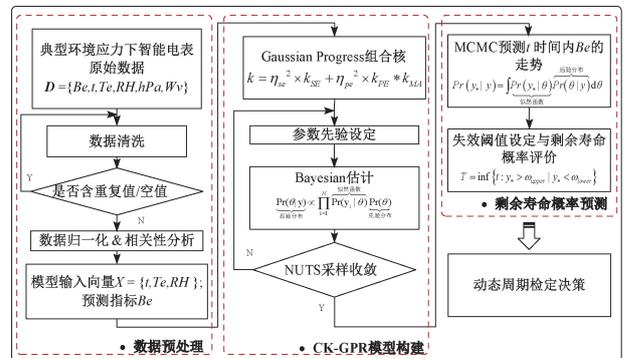


图 2 CK-GPR 模型算法实验流程

Fig. 2 The experiment flowchart of CK-GPR model algorithm

3 实例分析

3.1 典型环境应力下智能电表数据

如图3所示,对新疆地区2017年12月至2019年10月的智能电表的挂网试验基本误差数据以及环境变化数据进行采样并分析,智能电表样本来自A、B两家不同的智能电表制造公司。所有数据均按月独立抽取,每个样本包含2017~2019年间的23个数据点。采用基于PyMC3概率编程库的Python语言进行实验分析,仿真环境为Jupyter Notebook。



图3 新疆智能电表现场运行试验

Fig. 3 Field operation test of Xinjiang smart meter

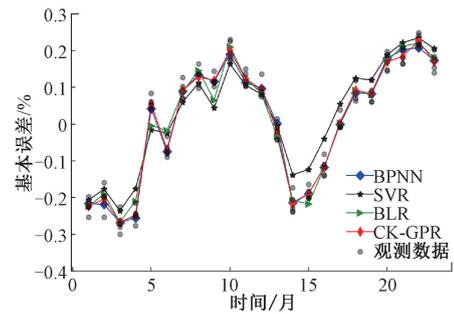
为了验证本模型的有效性和精度,对几种常用的时间序列模型进行回归拟合预测。三层后向传播神经网络(back propagation neural network, BPNN)、贝叶斯线性回归(bayesian liner regression, BLR)、gamma系数为0.05的RBF支持向量机回归(support vector regression, SVR)以及本文提出的组合核高斯过程回归的拟合结果如图4所示。从拟合轨迹来看,3种拟合曲线较为接近,但CK-GPR的拟合轨迹在真实数据点处更能跟踪数据点的变化,如图4(a)、(b)中第5个月以及第9个月处只有CK-GPR模型的拟合曲线在数据点上。

为在数值上体现拟合效果,采用均方根误差(root mean square error, RSME)和决定系数(R square, R^2)两种指标来评价4种方法的回归效果。

$$RMSE = \sqrt{\frac{1}{m} \sum_{i=1}^m (y_i - y_*)^2} \quad (18)$$

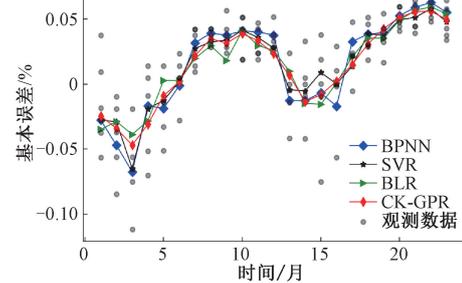
$$R^2 = 1 - \frac{\sum_{i=1}^m (y_i - y_*)^2}{\sum_{i=1}^m (y_i - \bar{y})^2} \quad (19)$$

4种回归效果RMSE和 R^2 对比如表1所示。可看出A公司数据CK-GPR的RMSE值为0.0213,小于其他3种方法,同时 R^2 为0.982,是方法间最大值;对于B公司,几种方法的 R^2 值处在0.6~0.7之间,这是由于B公司不同智能电表基本误差数据相对离散的结果。A、B公司不同数据集拟合效果的差异,如图4观测数据点,B公



(a) A公司数据不同方法拟合曲线

(a) Fitting curve using different methods for company A's data



(b) B公司数据不同方法拟合曲线

(b) Fitting curve using different methods for company B's data

图4 不同时间序列模型方法对比

Fig. 4 Comparison of different time series model methods

司数据数值范围小,但同属于B公司内部的电表数据差异较大,数据不够集中,致使BPNN,SVR,BLR,CK-GPR等方法对原始数据的拟合能力出现不同程度的下降。但对于长期预测,影响甚微,高斯过程回归可跟随基本误差的周期性变化趋势,且CK-GPR模型对智能电表基本误差数据有较好拟合性。本文所提出CK-GPR算法具有利用随机过程预测未来趋势的优势,且针对按月进行的时间外推预测,不需要月内其间大量数据训练来提高准确度,更适合按月抽样的小样本数据。

表1 不同模型RMSE和 R^2 对比结果

Table 1 Comparison results of the RMSE and R^2 for different models

评价指标	A公司		B公司	
	RMSE	R^2	RMSE	R^2
BPNN	0.023 1	0.979	0.021 5	0.677
SVR	0.050 2	0.904	0.021 4	0.681
BLR	0.032 3	0.961	0.023 6	0.612
CK-GPR	0.021 3	0.982	0.022 0	0.662

3.2 寿命预测实验对比与分析

考虑直接可观测的退化过程,以当前第23个月的运行时刻,利用本文方法预测智能电表在新疆吐鲁番地区投入第84个月后基本误差变化情况。由A、B两公司智

智能电表的基本误差是否达到给定阈值的情况,判定对应公司智能电表是否失效,即智能电表寿命是否终结。并借助后验轨迹达到阈值对应的时间来给出A、B两公司智能电表的失效时间的概率结果。

使用NUTS采样器,预烧期设置为1 000,对马尔科夫链进行模型的超参数3 000次迭代抽样,至其达到均衡分布之后,可从后验分布中抽取一个无限多数量的样本序列以得到最大概率值,这里抽取1 000个样本序列模拟1 000块智能电表在“高干热”典型环境下的运行状况。后验分布基于模型结构和数据集反映参数的后验不确定性,可提取一个集中趋势和后验可信区间的度量。以A公司数据为例,组合核后验参数如表2。

表2 GPR组合核MCMC后验参数

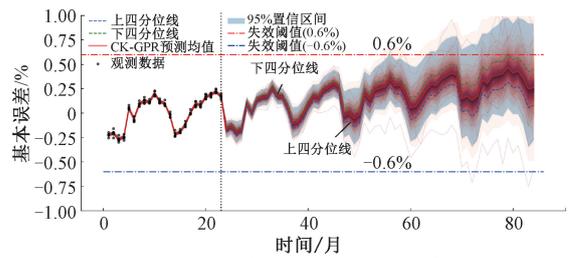
Table 2 Posterior parameters of GPR combined kernel using MCMC

超参数	均值	方差	MCMC 抽样误差	2.5% 分位数	97.5% 分位数
p	22.996	0.052	0.002	22.892	23.099
η_{pe}	0.304	0.279	0.013	0.017	0.805
l_{ma}	133.920	39.757	1.379	54.037	202.143
l_{pe}	0.479	0.269	0.016	0.028	0.901
η_{se}	1.567	1.369	0.075	0.031	4.159
l_{se}	45.970	18.279	0.697	13.698	83.139
δ	0.024	0.002	0.000	0.020	0.028

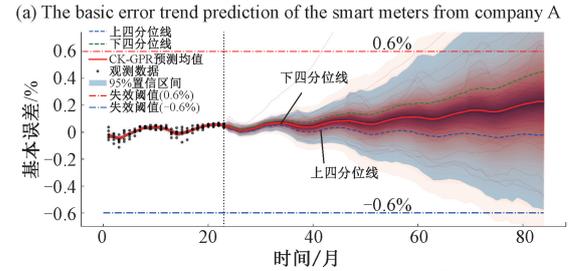
$\eta_{pe} = 0.304$, $l_{ma} = 133.92$,表明在134个月内基本误差都会保持0.304%幅度的不规则周期性变化,说明周期性会在长时间内保持,周期平滑度 l_{pe} 为0.479。 $\eta_{se} = 1.567$, $l_{se} = 45.97$,表明平均趋势幅度1.567%持续了46个月。 δ 表示可能会出现噪声, $\delta = 0.02\%$ 也是合理的。周期参数 $p = 22.996$,是以当前运行时间23个月为先验周期,防止A公司智能电表数据间变化波动大,导致大趋势出现多个周期参数从而过拟合。表2后验参数的MCMC抽样误差情况可知各参数求解是准确的。

由图5可看出,A、B公司预测趋势的95%置信区间均呈现一定趋势的向后扩散。这是随机过程NUTS采样的分布结果,反映高斯过程无限随机变量的联合分布;由于核函数是单调递减函数,样本间的相关性与样本间距离成反比,也即预测时间线越长,预测能力相应减弱,但集中趋势能较为准确地反映基本误差的长期变化。

基本误差预测均值均向正阈值方向增加,说明新疆高干热典型环境对智能电表基本误差的影响趋向正向失效。由图4原始观测数据可看出A、B不同公司智能电表产品对典型环境适应性具有差异,A公司智能电表的



(a) A公司智能电表基本误差趋势预测



(b) B公司智能电表基本误差趋势预测

(b) The basic error trend prediction of the smart meters from company B

图5 A、B公司智能电表基本误差趋势预测图

Fig. 5 The basic error trend prediction diagram of the smart meters from company A and B

基本误差预测值幅度变化大,B公司智能电表基本误差值幅度变化小,同时二者都具有周期性,这是周期变化的环境应力对它们造成的影响。A、B不同公司智能电表产品有所差异,但本文CK-GPR方法能够克服这种不同公司产品性能的差异性并给出预测,证明了本方法的通用性。

图5(a)、(b)的预测图中深色轨迹是高斯过程后验的样本。随运行时间增加,基于首达阈值的失效概率逐步增加。后验样本给出了一系列可能的未来轨迹,它们对观测到的数据进行推断,代表未来的基本误差合理轨迹,可用后验样本来定义置信区间。基本误差预测轨迹表明,在未来运行84个月里,智能电表可能向正阈值方向失效或者向负方向阈值失效。依照当前两年的数据来看,其均值趋势为正方向失效,这说明在高干热典型环境的影响下,智能电表基本误差正向失效的概率较大。如图5所示,为了更为准确地描述基本误差的轨迹变化,上、下四分位线内的基本误差变化趋势更为合理,代表了“高干热”典型环境下智能电表的集中退化趋势。智能电表典型环境现场运行试验作为国家计量标准验证试验,基于本模型的长期运行结果可作为参考解释与预警,随着运行时间的进行,置信区间相对较小的短期预测具有较高的准确性。

3.3 寿命预测概率密度

为得到更为直观的电表剩余寿命情况,由后验预测轨迹可求得A、B两公司智能电表的剩余寿命概率密度图分别如图6(a)、(b)所示。图6柱图为后验轨迹

首达阈值 RUL 统计值所得,曲线为将后验轨迹无穷化所得穿过失效阈值的 RUL 概率密度图。定义概率密度图中,峰值为可疑 RUL。如图 5 所示,智能电表基本误差数据随环境变化而发生周期上升的退化过程,任何意外情况,如电磁辐射、跌落等都有可能致使其超差失效,但这种事件罕见,并不可疑。本文预定义了基本误差首达阈值为智能电表寿命终结,急需进行误差检定工作,所以峰值是按照当前数据预测最大可能寿命终结的剩余寿命。可疑 RUL 预测具有利用当前数据提前预警提示的作用。

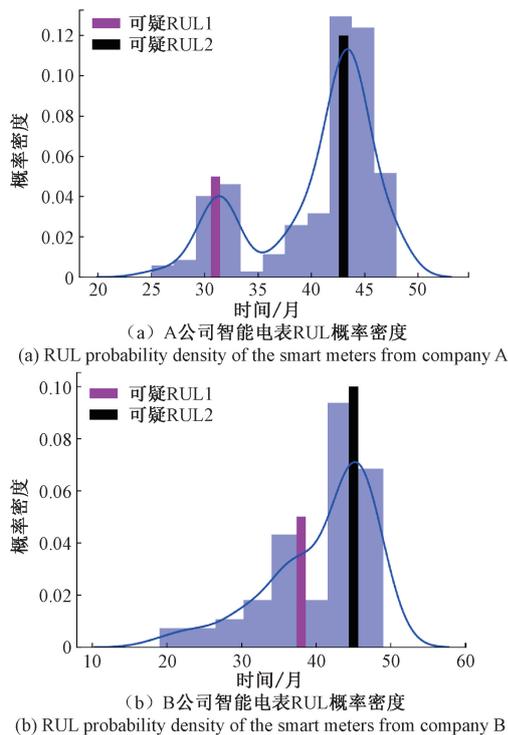


图6 智能电表剩余寿命后验分布

Fig. 6 RUL posterior distribution of smart meters

由图 6(a) 可知, A 公司的智能电表在新疆地区高干热典型环境应力影响下, 剩余使用寿命的概率密度出现了 2 个峰值, 可疑 RUL 为未来第 31 和第 43 个月。其最大可疑 RUL 为 43 个月, 也即基于当前运行情况, A 公司智能电表在此后运行第 43 个月失效的概率最大, 应当引起注意, 需要开始着手进行故障排查和检定。考虑峰值出现的时间差为 12 个月, 即智能电表失效会集中在一个周期内固定的月份。

如图 5(b) 所示, B 公司的智能电表在 84 个月预测时间内其 CK-GPR 模型后验中均值和上下四分位线均未达到失效阈值, 未有普遍基本误差超差失效的现象发生。这与原始数据中, B 公司智能电表基本误差数据受典型环境影响相对较小相吻合。由图 6(b), 其剩余

使用寿命的概率密度出现两个峰值, 可疑 RUL 分别为未来第 36 个月和第 47 个月。可疑 RUL 时间差与上述 A 公司较吻合, 说明新疆高干热典型环境对不同公司的智能电表具有相同的影响。由于同季节气候差异不大, B 公司智能电表最可能超差失效的时间区间为继续运行 46~48 个月, 即可在未来 47 个月附近对 B 公司进行误差检定, 该结果置信度为 95%。综合可得, B 公司智能电表产品相对 A 公司智能电表产品可靠性更高的结论。

4 结 论

智能电表在多应力典型环境下会出现加速性指标超差, 本文提出了一种基于组合核高斯过程回归的剩余寿命预测方法, 通过多匹配方式描述智能电表数据趋势特征, 实现对智能电表寿命的概率推理, 为智能电表在典型环境下性能变化提供了理论依据。结合智能电表在新疆地区的实际运行数据, 依据高干热典型环境下的实验数据进行回归预测, 不同方法的对比实验结果表明, 本文的 CK-GPR 模型具备更优的智能电表基本误差数据跟踪与预测能力, 可以准确预估智能电表在高干热典型环境下的失效方向; 智能电表的准确剩余寿命概率结果可为智能电表在典型环境下剩余寿命预测、可靠性评估与智能电表定期更换提供可靠依据。在本文工作的基础上, 后续还可建立其他如高海拔、高盐雾等典型环境对智能电表退化情况的影响模型, 进行误差变化趋势识别, 以进一步开展面向典型环境的检定周期标准制定, 也可从多退化指标进行更综合的可靠性评估与预测。

参考文献

- [1] 王思彤, 周晖, 袁瑞铭, 等. 智能电表的概念及应用[J]. 电网技术, 2010, 34(4): 17-23.
WANG S T, ZHOU H, YUAN R M, et al. The concept and application of smart meters [J]. Power System Technology, 2010, 34(4): 17-23.
- [2] 孙羽, 王秀丽, 王建学, 等. 电力系统短期可靠性评估综述[J]. 电力系统保护与控制, 2011, 39(8): 143-154.
SUN Y, WANG X L, WANG J X, et al. An overview of the short-term reliability evaluation of power system [J]. Power System Protection and Control, 2011, 39(8): 143-154.
- [3] 全国电磁计量技术委员会. 电子式交流电能表: JJG596-2012 [S]. 北京: 中国质检出版社, 2013: 2.
National Electromagnetic Metrology Technical Committee.

- Electronic AC energy meter: JJG596-2012 [S]. Beijing: China Quality Inspection Press, 2013; 2.
- [4] 刘天宇. 复杂退化过程下产品可靠性评估与剩余寿命预测方法研究[D]. 长沙:国防科学技术大学, 2016.
- LIU T Y. Research on product reliability evaluation and remaining life prediction methods under complex degradation process [D]. Changsha: National University of Defense Technology, 2016.
- [5] 李晓阳,姜同敏. 加速寿命试验中多应力加速模型综述[J]. 系统工程与电子技术, 2007(5): 828-831.
- LI X Y, JIANG T M. Summary of multi-stress acceleration models in accelerated life testing[J]. System Engineering and Electronic Technology, 2007 (5): 828-831.
- [6] 彭宇,刘大同. 数据驱动故障预测和健康管理综述[J]. 仪器仪表学报, 2014, 35(3): 481-495.
- PENG Y, LIU D T. Overview of data-driven failure prediction and health management[J]. Chinese Journal of Scientific Instrument, 2014, 35(3): 481-495.
- [7] 胡昌华,施权,司小胜,等. 数据驱动的使用寿命预测和健康管理技术研究进展[J]. 信息与控制, 2017, 46(1): 72-82.
- HU CH H, SHI Q, SI X SH, et al. Data-driven life prediction and health management technology research progress[J]. Information and Control, 2017, 46(1): 72-82.
- [8] 胡昌华,樊红东. 设备剩余寿命预测与最优维修决策[M]. 北京:国防工业出版社, 2018.
- HU CH H, FAN H D. Estimation of equipment remaining life and optimal maintenance decision [M]. Beijing: National Defense Industry Press, 2018.
- [9] 杜党波,司小胜,胡昌华,等. 基于随机退化建模的共载系统寿命预测方法[J]. 仪器仪表学报, 2018, 39(8): 53-62.
- DU D B, SI X SH, HU CH H, et al. Life prediction method of shared load system based on stochastic degradation modeling[J]. Chinese Journal of Scientific Instrument, 2018, 39(8): 53-62.
- [10] 李贺龙,于海波,何娇兰. 基于数据融合方法的智能电能表运行剩余寿命预测[J]. 电测与仪表, 2019, 56(18): 126-133.
- LI H L, YU H B, HE J L. Prediction of remaining operating life of smart electric energy meters based on data fusion methods [J]. Electrical Measurement and Instrumentation, 2019, 56(18): 126-133.
- [11] RASMUSSEN C E. Gaussian processes for machine learning[M]. MIT Press, 2006
- [12] 彭虹桥,顾洁,胡玉,等. 基于混沌粒子群—高斯过程回归的饱和负荷概率预测模型[J]. 电力系统自动化, 2017, 41(21): 25-32+155.
- PENG H Q, GU J, HU Y, et al. Saturated load probability prediction model based on chaotic particle swarm optimization and Gaussian process regression[J]. Automation of Electric Power Systems, 2017, 41(21): 25-32+155.
- [13] 庞景月,马云彤,刘大同,等. 锂离子电池剩余寿命间接预测方法[J]. 中国科技论文, 2014, 9(1): 28-36.
- PANG J Y, MA Y T, LIU D T, et al. Indirect prediction method for remaining life of lithium-ion battery [J]. Chinese Science and Technology Paper, 2014, 9(1): 28-36.
- [14] 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. MBBS-based failure rate prediction of electric energy metering equipment[J]. Chinese Journal of Scientific Instrument, 2019, 40(1): 43-51.
- [15] 阙子俊,金晓航,孙毅. 基于UKF的轴承剩余寿命预测方法研究[J]. 仪器仪表学报, 2016, 37(9): 2036-2043.
- QUE Z J, JIN X H, SUN Y. Research on the prediction method of bearing remaining life based on UKF [J]. Chinese Journal of Scientific Instrument, 2016, 37(9): 2036-2043.
- [16] 全国信息与文献标准化技术委员会. 标准电能表: GB/T 17215. 701-2011 [S]. 北京:中国标准出版社, 2011:7.
- National Information and Document Standardization Technical Committee. Standard watt-hour meter: GB/T 17215. 701-2011 [S]. Beijing: China Standards Press, 2011:7.
- [17] 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 prediction of intelligent electricity meter based on ZINB hierarchy bayes [J]. Journal of Electronic Measurement and Instrumentation, 2019, 33(7): 28-36.
- [18] RODGERS J L, NICEWANDER W A. Thirteen ways to look at the correlation coefficient [J]. The American Statistician, 1988, 42(1): 59-66.
- [19] 孙斌,姚海涛,刘婷. 基于高斯过程回归的短期风速预测[J]. 中国电机工程学报, 2012, 32(29): 104-109+5.
SUN B, YAO H T, LIU T. Short-term wind speed prediction based on Gaussian process regression [J]. Proceedings of the Chinese Society of Electrical Engineering, 2012, 32(29): 104-109+5.
- [20] CAI B, HUANG L, XIE M. Bayesian networks in fault diagnosis [J]. IEEE Transactions on Industrial Informatics, 2017, 13(5): 2227-2240.
- [21] WATANABE S. Asymptotic equivalence of bayes cross validation and widely applicable information criterion in singular learning theory[J]. Journal of Machine Learning Research. 2010, 11(18): 3571-3594.

作者简介



段俊峰, 2018 年于西安建筑科技大学获得学士学位, 现为湖南大学硕士研究生, 主要研究方向为可靠性和智能检测与仪器。

E-mail: duanjunfeng@hnu.edu.cn

Duan Junfeng received his B. Sc. degree in 2018 from Xi'an University of Architecture and Technology; now, he is an M. Sc candidate in Hunan University. His main research interest includes reliability and intelligent detection and instrument.



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 systems.