

DOI: 10.19650/j.cnki.cjsi.J2108777

多应力下电能计量设备基本误差预估*

覃玉红,唐 求,邱 伟,段俊峰,韩 敏
(湖南大学电气与信息工程学院 长沙 410082)

摘 要:针对典型环境应力下电能计量设备基本误差受环境应力影响大,且多电应力间关系难以刻画的问题,提出一种改进粒子群长短时记忆网络(IPSO-LSTM)的电能计量设备基本误差预测方法。首先,对典型环境下多种应力数据进行归一化、数据集分配预处理;针对误差时序数据波动趋势,构建一种挤压 LSTM 网络结构以分析误差数据的变化趋势特征,以改善多应力数据下的模型非线性拟合能力;利用改进 PSO 算法对模型超参数进行寻优,减少模型超参数影响,增强模型预测效果。在实验部分,依据某公司的多个电能计量设备,结合新疆地区典型运行试验室测量的环境应力及其误差数据对所提出算法进行验证分析。结果表明,本文的样本预测精度指标 RMSE 分别达到 1.08% 和 1.19%,MAE 分别达到 0.88% 和 0.96%。

关键词: 电能计量设备;多应力;挤压 LSTM;改进粒子群算法

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

Basic error estimate of electric energy metering equipment under multiple stresses

Qin Yuhong, Tang Qiu, Qiu Wei, Duan Junfeng, Han Min

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

Abstract: The basic error of electric energy metering equipment is greatly affected by environmental stress. And the relationship between multiple electrical stresses hard to be described under typical environmental stress. To address these issues, an improved particle swarm with long short-term memory network (IPSO-LSTM) is proposed to predict the basic error of electric energy metering equipment. Firstly, various stresses data in typical environment are normalized and data set allocation are preprocessed. To solve fluctuation trend of the error time series data, an extruded LSTM network architecture is established to analyze the variation trend characteristics of the error data. In this way, the nonlinear fitting ability of the model under multiple stress data is enhanced. Then, the improved PSO algorithm is used to optimize the model's hyperparameters to reduce the influence of hyperparameters and improve the prediction performance of the model. In the experimental part, the proposed algorithm is evaluated and analyzed according to several electric energy metering equipment of one company. The environmental stress and error data are both considered by typical operating laboratories in Xinjiang region. The results show that the sample prediction accuracy indexes RMSE values reach 1.08% and 1.19%, respectively. And MAE values reach 0.88% and 0.96%, respectively.

Keywords: electric energy metering equipment; multiple stresses; extruded LSTM; improved PSO

0 引 言

能源是现代社会的动力,随着国民经济的发展,

智能电能表、转变终端、低压计量箱等一批新型电能计量设备作为工业和民用能源计量的基础单元,将越来越多地被投入应用^[1]。电能计量设备测量的准确性、可靠性直接关系到国民经济发展的效益。然而,电能计量设备

在典型环境应力下运行极易出现老化^[2],在典型环境应力及不同电应力下的计量误差波动大,难以获得准确、真实的电能计量值。影响用户端用电量与发电侧发电计划。

电能计量设备的精确计量与可靠运行,关系到售电与用电双方的贸易结算是否公平、公正、合理^[3],并直接涉及到千百万用电用户的利益。现有的电能计量设备在出厂检验测试等环节中,通常在恒定环境应力、电应力或短时下测试,其检验结果与在典型运行试验下有显著差别。分析典型环境条件下电能计量设备的运行特性和可靠性,掌握其在各种环境应力和电应力影响干扰下的运行误差、变化规律及性能的差异,可作为电能计量设备改进设计制造及其轮换的主要依据^[4],也可为国家标准的验证提供理论支撑。

针对电能计量设备的计量误差及其可靠度分析问题,国内外学者进行了较为广泛的研究。文献[3]将电能计量设备的运行状态评价结果和失效数据关联,提出了一种电能计量设备的失效概率计算方法。文献[4]利用改进的模糊神经网络,对电能表分拣阶段的数据进行训练和预测,实现了电能表误差超差风险的概率预测。上述方法对电能计量设备的运行误差和可靠度研究具备一定的参考意义,但缺乏环境应力对电能计量设备影响的分析,降低了方法的实用性。文献[5-6]设计了电能计量设备的加速环境应力运行试验,并根据运行试验的数据轨迹,进行了可靠度分析。文献[7-8]利用 Copula 联结函数融合了电能计量设备在加速实验下的环境应力和电应力。此类研究综合了电能计量设备的环境应力及电应力,然而加速环境下的应力与典型环境应力仍然具有较大差异,无法对真实环境进行直接部署。文献[2,9-10]研究了典型环境下的电能计量设备轮换数据,通过多层贝叶斯算法,实现了典型环境下对电能计量设备的可靠度置信区间预测。上述文献中的轮换数据无法全面表征设备的失效与否,且不能实时反映电能计量设备的运行状态,从而限制了算法的实际应用效果。

电能计量设备在典型环境下的运行状态受多个环境应力、电应力,及其叠加累积效应影响,其中环境应力、电应力采用瞬时测量值来表征,时间应力为多种应力叠加下的累积效应,可用时间值来表征。这些应力具备数据量大、时间序列特征种类多的特点。而长短时记忆循环神经网络(long short-term memory, LSTM)在处理长时间序列及多维数据输入方面有广泛应用。如文献[11]利用模糊c均值聚类算法和 LSTM 对机床的温度点进行筛选和热误差的预测,所提出的模型提升了机床热误差的预测精度。文献[12]建立了基于 LSTM 的黑箱模型,解决了复杂工况下使用混合燃料 HCCI 发动机的燃烧正时估计问题。文献[13]利用 LSTM 和改进的卷积神经网络

(CNN)对计量不准确的电能计量设备进行检测、定位,后续进行更换以节约国家资源和成本。然而,LSTM 的模型超参数对模型精度有较大影响,上述方法多在人为经验的基础上对模型超参数进行选择,实际不同的模型超参数带来的训练速度、拟合能力等差异较为明显。本文为增强模型拟合效果,提高预测精度,构建挤压 LSTM 网络结构,此外,利用改进 PSO 算法对挤压 LSTM 网络超参数组合进行搜索寻优。

为综合分析典型环境下多个环境应力、电应力影响下的电能计量设备长时运行下的计量误差及可靠度,本文提出一种新型误差预测方法,主要研究内容为:

1)为充分考虑计量误差影响因素,本文融合典型环境下多个环境应力以及电应力因素,研究这些应力对电能计量设备长时运行下计量误差及可靠度的影响;

2)为提升误差预测效果,在传统 LSTM 网络基础上,提出一种挤压 LSTM 网络以提高对误差数据的非线性拟合能力;

3)为减小模型超参数对结果分析影响,结合改进 PSO 算法,实现对挤压 LSTM 模型超参数的优化选取;

4)结合模型提取的特征分析,评估各应力对电能计量终端的影响特征,并为售电与用电双方的贸易结算公平、公正、合理提供参考和建议。

1 电能计量设备数据分析

1.1 电能计量数据采集系统

典型环境下的电能计量设备测量准确度随着环境应力的变化而波动。新疆作为中国的西北门户,夏季的平均温度 40℃,最高温可达高达 70℃,最大相对湿度近 80%,而大部分地区常年降水量不足 150 mm,各地区寒暑及昼夜的温湿度差异悬殊,为典型的高干热环境^[14]。典型环境应力下的电能计量设备运行状态的研究有着重要意义^[15]。图 1 为新疆典型环境运行试验室电能计量设备数据采集系统。

如图 1 所示,典型环境运行试验室通过环境监测系统和电能计量设备监控系统分别进行各环境应力数据和设备运行数据的采集、记录,进一步与室内标准计量设备数据进行比对计算从而得到计量误差。然后,实验室将采集处理后的数据通过网络交换机或 GPRS 云上传至基站服务器和数据库进行存储。

1.2 电能计量数据

智能电能表作为主要的电能计量设备,其应用广、需求大,因此本文选择应用智能电能表作为研究对象。评估该类型设备测量准确性和可靠性的重要指标为基本误差,基本误差为计量检定规程《JJG-596-2012-电子式交

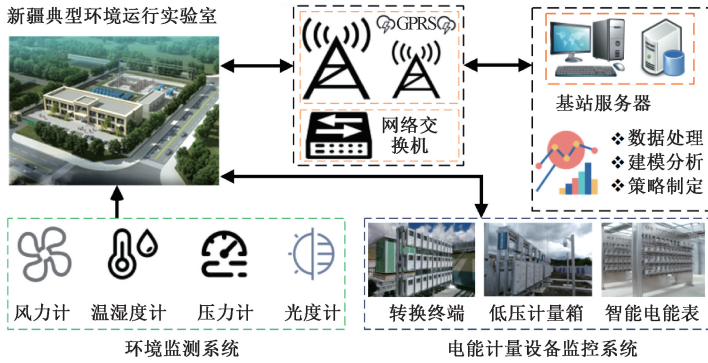


图1 电能计量设备数据采集系统

Fig.1 Electric energy metering equipment data collecting system

流电能表》中必要的性能特征^[16],其定义为:

$$y = \frac{P_{ref} - P_{test}}{P_{ref}} \times 100\% \quad (1)$$

式中: P_{ref} 表示电参数实际值, P_{test} 表示测量所得值, y 表示基本误差^[7]。

实验室实时测量的环境应力包括了温度(T)、湿度(R)、压强(P)、光照(V)和风速(W)。此外,测量的电应力(IP)包括了功率因数为1的 P_{max} 以及 P_s 、 $0.5P_s$ 、 $0.1P_s$ 和 $0.05P_s$, P_{max} 表示最大功率, P_s 为额定功率。如图2展示了同批次的两个智能电能表各电应力下的近两年不连续的基本误差曲线。




图2 不同电应力电能表基本误差分布

Fig.2 Basic error distribution of different electric stresses smart meters

由图2可知,同一公司同批次的电能表基本误差具有同质性;在不同电应力下的电能表的基本误差测量值具有相同的趋势,且具有明显的周期性,说明跟季节即温度等环境应力变化具有同步性,即在夏季具有偏正的计量误差,而在冬季的则相反;各应力的基本误差具有向负的偏置量,功率小的基本误差波动普遍较大,说明在低功率下,电能表的测量精度低于高功率下的测量。基于该现象,可采用数据驱动方法学习多应力下的趋势变化特征。

2 IPSO-LSTM 基本误差预估模型搭建

2.1 挤压 LSTM 网络结构

长短期记忆网络 and 传统循环神经网络最大的不同就是它使用了输入门、遗忘门和输出门来控制网络,从而解决了梯度爆炸和梯度消失的问题,能够更加高效地提取基本误差数据中的有用信息和关键特征。

设定在 t 时刻输入 LSTM 单元的高维应力变量为 \mathbf{x}_t ,模型输出值为基本误差 y_t ,其中 \mathbf{x}_t 包含了多个应力变量: $\mathbf{x}_t = [t, T, IP, P, V, W, R]$,LSTM 的基本原理为

$$f_t = \sigma(W_f[\mathbf{x}_t, H_{t-1}]^T + b_f) \quad (2)$$

$$o_t = \sigma(W_o[\mathbf{x}_t, H_{t-1}]^T + b_o) \quad (3)$$

式中: f_t 、 o_t 分别对应 LSTM 结构中的遗忘门、输出门,输入门包含了 i_t 、 \tilde{C}_t 两个状态量,其具体单元结构图可参见文献[11]; σ 、 \tanh 分别对应 Sigmoid 和 tanh 激活函数; W 和 b 分别代表了相应的权重矩阵和偏置系数; t 时刻的 LSTM 层记忆单元状态 C_t 、输出信息 H_t 推导为:

$$C_t = C_{t-1}f_t + i_t\tilde{C}_t \quad (4)$$

$$H_t = o_t \tanh(C_t) \quad (5)$$

为提高模型的预测精度,通过添加一种“挤压”性质的激活函数及全连接层,并将 LSTM 网络提取的特征矩阵作为挤压层输入,以更好地拟合多维特征应力下的数据^[17],从而提出一种挤压 LSTM 算法。该挤压 LSTM 通

过增加挤压层以实现更优的拟合和预测目标,提高模型泛化能力和预测精度。综合电能表的基本误差数据和多次测试结果,挤压 LSTM 挤压层组合为线性全连接层 Liner 和挤压函数 tanh。

LSTM 层的输出特征值经过挤压层和全连接层后,输出预测的基本误差值 y_t , 表达式如下

$$J_t = \tanh(\text{Liner}(H_t)) \quad (6)$$

$$y_t = \text{Liner}(J_t) \quad (7)$$

式中:网络将 LSTM 输出变量 H_t 输入至全连接层 Liner, 然后再通过 tanh 激活函数达到将变量挤压的效果。 J_t 为挤压层输出变量,模型最后通过 Liner 层对 J_t 处理后输出基本误差。所提出的挤压层主要目的是改善现有 LSTM 网络在多维输入数据下非线性拟合能力不足的问题,最后,将模型输入对应的输出概括为式子

$$y_t = \Psi(\mathbf{x}_t) \quad (8)$$

然而,众多超参数影响 LSTM 的预测模型,其中隐藏层大小 (Hs) 和学习率 (Lr) 影响最为关键^[18],为达到更好的预测效果,本文利用改进 PSO 算法对超参数 Hs 和 Lr 进行寻优。

2.2 改进 PSO 算法

为提高模型预测精度,减少人工对参数选择的影响,PSO 算法作为不需遍历全部参数空间即可寻找最优解的优化算法^[19],适用于挤压 LSTM 超参数组合 [Hs, Lr] 的空间寻优搜索。算法的基本思想是通过群体中个体之间的协作和信息共享来寻找最优解的粒子,各粒子分别对应一组超参数解即 $S = [Hs, Lr]$ 。PSO 的标准搜索更新形式为:

$$V_{i,j}^{t+1} = \omega V_{i,j}^t + c_1 r_1 (P_{best,i,j}^t - S_{i,j}^t) + c_2 r_2 (g_{best,i,j}^t - S_{i,j}^t) \quad (9)$$

$$S_{i,j}^{t+1} = S_{i,j}^t + \lambda V_{i,j}^{t+1} \quad (10)$$

式中: ω 表示惯性因子,且 $\omega > 0$; $V_{i,j}^t$ 粒子表示在第 t 次迭代中,第 i 个粒子在第 j 维上的速度量, p_{best} 表示个体最优值, g_{best} 为群体最优值, S 为所求超参数 [Hs, Lr] 位置量; c_1 和 c_2 为学习因子, r_1 和 r_2 为在 $[0, 1]$ 相互独立的均匀分布随机数; λ 为速度因子。

ω 的选取决定了粒子在全局探索和局部开采的平衡,当 ω 的取值较大时,粒子飞行速度较大。此处选择线性惯性权重递减方法,便于在前期粒子群全局搜索,后期粒子群的快速聚集增强局部搜索^[19]。

$$\omega = \omega_{\min} + \omega_L \left(1 - \frac{t}{M}\right) \quad (11)$$

式中, ω_{\min} 表示最小的权重值, ω_L 为限制惯性权重值。 M 为最大的迭代次数。

为增强粒子群的前期搜索能力,拓展搜索空间,同时保证后期的收敛性,引入变异因子^[20]和线性递减速度因

子,建立改进 PSO 算法。

改进 PSO 中变异因子目的为扩大粒子的搜索空间,速度因子则用于保证后期迭代搜索的收敛性,改进 PSO 算法改进表示如下:

$$V_{i,j}^{t+1} = \omega V_{i,j}^t + c_1 r_1 (P_{best,i,j}^t - S_{i,j}^t) + c_2 r_2 (g_{best,i,j}^t - S_{i,j}^t) + c_3 r_3 (g_{best,i,j}^t - S_{i,j}^t) \quad (12)$$

$$\lambda = 1 - \beta \times \frac{t}{M} \quad (13)$$

式中: c_3 学习因子为 $1 - t/M$, r_3 为在 $[0.4, 0.6]$ 区间均匀分布的随机数。 β 为速度因子限制系数,且 $\beta < 1$ 。改进 PSO 算法对挤压 LSTM 的超参数 [Hs, Lr] 进行高效寻优搜索。

2.3 IPSO-LSTM 模型搭建

为提升设备计量误差预测准确,保证挤压 LSTM 预测模型泛化性,在改进 PSO 中适应度函数对训练集和测试集的拟合结果进行结合:

$$fit = \frac{1}{n_1} \sqrt{\frac{1}{Z_{tr}} \sum_{p=1}^{Z_{tr}} (y_p - \Psi(\mathbf{x}_p, Hs, Lr))^2} + \frac{1}{n_2} \sqrt{\frac{1}{Z_{te}} \sum_{q=1}^{Z_{te}} (y_q - \Psi(\mathbf{x}_q, Hs, Lr))^2} \quad (14)$$

式中: fit 为适应度函数, Z_{tr} 为训练的样本总数, Z_{te} 为测试的样本总数, $\Psi(\mathbf{x}, Hs, Lr)$ 表示挤压 LSTM 模型在设定 [Hs, Lr] 下输入多应力数据 x 后的模型输出值。 n_1 和 n_2 分别为对应的电应力个数,从适应度可以考虑对不同样本的重视度。

结合改进 PSO 与挤压 LSTM 方法,本文进一步提出一种 IPSO-LSTM 模型算法,其结构如图 3 所示。

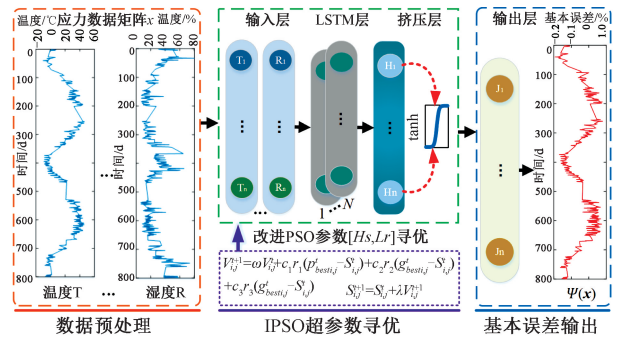


图 3 IPSO-LSTM 网络结构

Fig. 3 Architecture of the IPSO-LSTM network

IPSO-LSTM 模型算法流程如下:

- 1) 对实验数据按照不同应力进行归类、归一化等预处理,然后随机划分为训练集、测试集、预测集。
- 2) 建立挤压 LSTM 模型,并设置超参数区间,包括训练迭代次数, Hs 和 Lr 的搜寻区间;将粒子群参数初始化,包括种群规模、最大迭代次数、最小学习精度、学习因子、

惯性权值系数和速度因子等设置;

3) 将初始化的粒子群以及训练集、测试集数据带入挤压 LSTM 模型, 利用式 (14) 计算适应度值。并比较各粒子的适应度值, 把每个粒子的当前适应度值作为个体最佳位置 p_{best} , 并选择最优适应度值的粒子为全局最优解 g_{best} 。

4) 根据 p_{best} 和 g_{best} 以及式 (10)、(12) 进行更新粒子的速度和位置, 将各粒子 $S = [H_s, L_r]$ 带入 LSTM 模型。

5) 通过式 (14) 计算新的适应度值后, 通过粒子间的比较, 更新 p_{best} 和 g_{best} 。

6) 判断是否达到最大迭代次数或最小学习精度, 若没有达到, 则返回步骤 4), 直到满足终止条件。

7) 将预测集输入模型进行预测, 输出预测的基本误差序列, 对各应力影响进行评估。

为进一步量化模型的拟合及预测效果, 利用均方根误差 (root mean square error, RMSE) 和平均绝对误差 (mean absolute error, MAE) 用于模型结果评估。RMSE 和 MAE 计算公式分别为:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (15)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (16)$$

3 实验分析

为验证所提出方法的科学合理性, 从新疆典型环境运行试验室的运行数据中随机选取某公司的多个智能电表 2017 年 12 月~2020 年 5 月的不连续运行基本误差数据, 及其对应的 5 种电应力和各个环境应力进行验证。按照应力的差异进行样本随机划分, 其中, 训练集、测试集和预测集的样本按照 3:1:1 比例进行划分。该研究选取了 P_{max} 、 P_s 、 $0.05P_s$ 及其对应的环境应力为训练集, $0.1P_s$ 及其对应环境应力为测试集, $0.5P_s$ 及其对应环境应力为预测集。图 4 为新疆典型环境运行实验室现场运行图。

该模型搭建基于 Pytorch 10.0 平台, 为综合考虑在最低 L_r 和最小 H_s 以及最高 L_r 和最大 H_s 下挤压 LSTM 网络的收敛性和运算速度, 本文选择 LSTM 的迭代次数为 200, 设置 H_s 和 L_r 搜索区间为 $[10 \sim 120, 0.001 \sim 0.5]$ 。针对基本误差数据受噪声影响大, 采用适用于嘈杂和稀疏梯度的 Adam 梯度下降法。

3.1 IP SO 算法验证

为验证 IP SO 算法的有效性, 对 PSO 算法改进前后进行对比分析。考虑实验数据基本误差的数量级较小, 为保证算法的收敛性和运算速度, 改进 PSO 算法中参数惯性权值 ω_{min} 、 ω_L 分别取值 0.4、0.3, 学习因子 c_1 和 c_2



图 4 新疆智能电能表现场运行试验

Fig. 4 Field operation experiment of the Xinjiang smart meter

为 0.4^[21], 速度因子限制系数 ω 为 0.8。未改进 PSO 算法参数 ω 为 0.7, 学习因子 c_1 和 c_2 为 0.4。两种算法的种群数和迭代次数都分别为 15 和 100, 带入挤压 LSTM 网络超参数寻优实验, 运行结果如图 5 所示。




图 5 改进 PSO 算法迭代

Fig. 5 The improved PSO algorithm iteration

由图 5 可知, IP SO 算法在迭代 26 次后即稳定, 而 PSO 算法需在 45 次后才稳定。此外, IP SO 稳定后的适应度指标比 PSO 低 0.000 2。改进后的 PSO 算法不仅能克服早熟问题, 前期具有更高效的参数搜索能力, 还具有更快的收敛速度。IP SO 搜索的最优超参数隐藏层大小和学习率组合为 $[27, 0.03]$ 。模型训练消耗时间为 7 924 s, 预测时间 0.05 s, 但本文对模型的实时性要求不高, 故可采用离线训练方式对数据进行拟合以及预测。

3.2 模型对比及预测分析

将求解的最优超参数带入挤压 LSTM 模型进行基本误差预测, 为验证本文模型的拟合效果和预测能力, 同时选择多层感知机 (multilayer perceptron, MLP)^[15]、支持向量机 (support vector machines, SVM)^[15]、BP 神经网络 (back propagation neural network, BP)^[14]、未改进的

LSTM(L-LSTM)^[11]网络与本文方法进行对比。此外,对比方法的参数经过多次实验选择最优组合。其中,MLP 的层数为 10,每层的神经元个数为 140;SVM 采用高斯核,惩罚系数为 10 000,伽马参数为 0.001;BP 神经网络的隐含层节点数根据经验公式计算,选取为 12,学习率为 0.15。图 6 为各模型输入预测集后的基本误差预测结果。




图 6 不同模型预测图

Fig. 6 Prediction diagrams of different models

由图 6 可知,各个模型均能预测基本误差的周期趋势。但是,SVM 和 BP 模型的预测结果较差,预测结果整体波动小,较难满足基本误差的波动趋势。L-LSTM、MLP 和 IPSO-LSTM 模型能很好跟随真实值的变化趋势。MLP 模型的预测值相对于真实值,整体偏高。从两图局部放大的预测结果可知 LSTM 的两种模型在长时波动趋势的跟随方面更具优势。

为量化分析基本误差的预测结果,图 7、8 分别列出各模型的拟合及预测的各样本 RMSE 和 MAE 值。RMSE1、MAE1 和 RMSE2、MAE2 分别表示电能表 1 和电能表 2 的计算结果。

由图 7 中两个电能表的多个指标表明了本文模型、LSTM 和 MLP 的拟合效果明显优于 SVM 和 BP 神经网络,而 LSTM 的两种模型较 MLP 也是较优的。电能表在本文模型的拟合效果 RMSE 分别为 0.010 1、0.106,MAE 为 0.007 7、0.007 6,相较于 L-LSTM 模型 RMSE 减少 0.001 4、0.004 3,MAE 降低 0.001 1、0.004 3,有较大优势。本文模型的指标为所有模型中最优的。

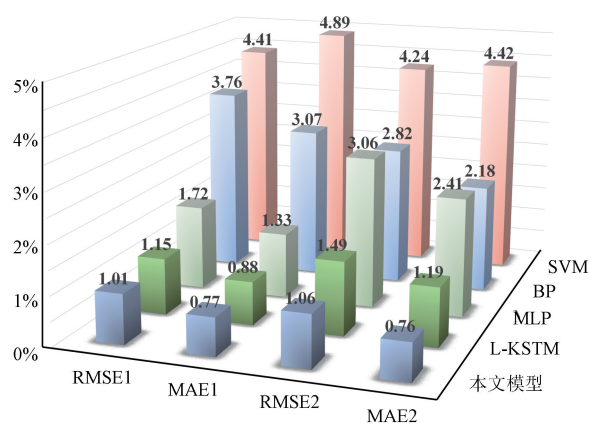


图 7 各模型拟合比较值

Fig. 7 Fitting value comparison of each model




图 8 各模型预测比较值

Fig. 8 Prediction comparison of each model

对于模型预测能力,由图 8 可得结论与图 7 类似。综合图 7 和 8 可知,SVM 模型在本数据的试验中效果最差。而本文模型与 L-LSTM 预测的两种模型指标十分相近,但本文模型仍较优于 L-LSTM 模型。说明两种 LSTM 模型相比其他模型,均有较大的泛化能力。

3.3 模型提取特征分析

为进一步研究模型的特征提取能力,本文选用最大信息系数(maximum information coefficient, MIC)对模型挤压层输出的高维特征向量与模型输入应力变量进行相关性处理。MIC 被广泛应用于变量之间的线性、非线性相关性检测;MIC 值越大,表示特征之间的相关性越强。本文选择输入的高维特征向量与输入特征值的 MIC 均值的特征相关性分析如图 9 所示

由图 9 可知,两个样本的时间应力和温度应力与模型的特征 MIC 值相近,且明显高于其他应力,说明这两个应力与电能表的基本误差值相关性最大。同时,时间应力的相关性值说明了模型有效提取了基本误差周期性。功率的 MIC 对比风速和光照应力的 MIC 值,表明其

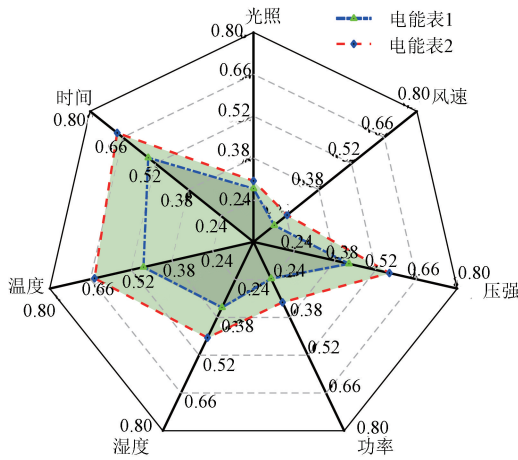


图9 特征相关性图

Fig. 9 Feature correlation graph

有较大的相关性。电能表1和电能表2的MIC整体差异表明了电能表一的基本误差具有较大的噪声,此外,两表特征覆盖的阴影形状说明了各应力对电能表作用的同一性。

基于上述的特征分析,在电能表的计量过程中,对于电力运营公司的电能计量误差,通过对大数据下不同用户的用电数据全息感知、计量装置在线误差监测,实行对不同用户实行动态定价及电价补偿等措施。如:对于电能计量设备的计量误差整体的偏置问题,通过误差监测系统对偏置进行纠正;对于计量误差整体的季节周期性,实行不同季节进行相应的动态定价;对于用户的用电习惯、用电量大小差异进行合理的电价补偿。譬如针对高用电用户,在夏季的整体计量误差偏正情况下,执行适当降低电价的政策,而在冬季进行的整体计量误差偏负情况下,则反之。

4 结论

为研究典型环境应力下电能计量设备长时运行的基本误差随环境应力变化大,且不同电应力之间变化趋势难以刻画的难题,本文提出一种挤压LSTM的预测模型,并利用改进PSO算法对挤压LSTM模型超参数进行搜索寻优。通过对比改进PSO算法与未改进PSO算法对挤压LSTM超参数寻优结果,验证了改进PSO能更快收敛,表明了其优越性;基本误差预测实验结果表明,相比典型数据驱动算法(SVM,MLP等)而言,该模型具有更强的泛化能力和更高的预测精度,且对缺失数据具有鲁棒性。利用输入的高维特征向量与输入特征值的相关性分析,对模型的特征提取能力进行了检验,结果表明模型能很好提取输入的多维应力特征,同时剖析了典型环境应力对误差的影响程度。

参考文献

- [1] SUN Q, LI H, MA Z, et al. A comprehensive review of smart energy meters in intelligent energy networks[J]. IEEE Internet of Things Journal, 2016, 3(4): 464-479.
- [2] 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.
- [3] RUI W, HAI B Y. Failure risk assessment method of electric energy meter based on state evaluation[C]. 2016 China International Conference on Electricity Distribution (CICED), 2016: 1-5.
- [4] 金阳忻.基于模糊神经网络的电能表误差超差风险预测模型[J].电网技术,2019,43(6):1962-1968.
- [5] JIN Y Q. Electrical power meter error overproof calculation model based on fuzzy neural network[J]. Power System Technology, 2019, 43(6): 1962-1968.
- [6] YE T, PANG B, ZHOU Y, et al. Research on accelerated life test of smart meter based on degraded trajectory model[C]. The International Conference, 2018: 1-5.
- [7] YANG Z, CHEN Y X, LI Y F, et al. Smart electricity meter reliability prediction based on accelerated degradation testing and modeling[J]. International Journal of Electrical Power & Energy Systems, 2014, 56: 209-219.
- [8] XU D, XING M, WEI Q, et al. Failure behavior modeling and reliability estimation of product based on vine-copula and accelerated degradation data[J]. Mechanical Systems and Signal Processing, 2018, 113: 50-64.
- [9] XU D, WEI Q, ELSAYED E A, et al. Multivariate degradation modeling of smart electricity meter with multiple performance characteristics via vine copulas[J]. Quality and Reliability Engineering International, 2017, 33(4): 803-821.
- [10] 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.
- 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] 谭峰,李成南,萧红,等.基于 LSTM 循环神经网络的数控机床热误差预测方法[J].仪器仪表学报,2020,41(9):79-87.
- TAN F, LI CH N, XIAO H, et al. A thermal error prediction method of CNC machine tools based on LSTM recurrent neural network [J]. Chinese Journal of Scientific Instrument, 2020, 41(9): 79-87.
- [12] 郑太雄,贺吉,张良斌.基于 LSTM 神经网络的混合燃料 HCCI 发动机复杂工况下燃烧正时估计[J].仪器仪表学报,2020,41(10):100-110.
- ZHENG T X, HE J, ZHANG L B. Combustion timing estimation of the HCCI engine with mixed fuel under complex operating conditions based on LSTM neural network[J]. Chinese Journal of Scientific Instrument, 2020, 41(10): 100-110.
- [13] LIU M, LIU D, SUN G, et al. Deep learning detection of inaccurate smart electricity meters: A case study[J]. IEEE Industrial Electronics Magazine, 2020, 14(4): 79-90.
- [14] 段俊峰,李宁,唐求,等.基于 CK-GPR 的多应力环境智能电表剩余寿命预测[J].仪器仪表学报,2021,42(4):102-110.
- DUAN J F, LI N, TANG Q, et al Remaining useful life prediction of smart meter based on CK-GPR in multi-stress environment [J]. Chinese Journal of Scientific Instrument, 2021, 42(4): 102-110.
- [15] QIU W, TANG Q, TENG ZH SH, et al. Failure rate prediction of electrical meters based on weighted hierarchical Bayesian[J]. Measurement, 2019, 142: 21-29.
- [16] 全国电磁计量技术委员会.中华人民共和国国家计量检定规程:JJG 596-2012[S].电子式交流电能计量设备,2012.
- National Technical Committee for Electromagnetic Measurement. National metrological verification regulations of the People's Republic of China: JJG 596-2012[S]. Electrical Meters for Measuring Alternating current Electrical Energy, 2012.
- [17] BARRON A R. Universal approximation bounds for superpositions of a sigmoidal function [J]. IEEE Transactions on Information Theory, 1993, 39(3): 930-945.
- [18] 吴宗收,汪立新,李新三,等.一种改进 PSO-ARMA 半球谐振陀螺温度误差建模方法[J].北京航空航天大学学报,2021,1-9.
- WU Z SH, WANG L X, LI X S, et al. An improved PSO-ARMA method in temperature error modeling of HRG[J]. Journal of Beijing University of Aeronautics and Astronautics, 2021, 1-9.
- [19] 邱伟,唐求,林海军,等.基于 PSO-LSSVM 的水分仪称重传感器非线性补偿研究[J].仪器仪表学报,2017,38(3):757-764.
- QIU W, TANG Q, LIN H J, et al. Study on weighing sensor's nonlinear compensation of the moisture instrument based on PSO-LSSVM[J]. Chinese Journal of Scientific Instrument, 2017, 38(3): 757-764.
- [20] GREFF K, SRIVASTAVA R K, KOUTNÍK J, et al. LSTM: A search space odyssey[J]. IEEE Transactions on Neural Networks and Learning Systems, 2017, 28(10): 2222-2232.
- [21] SHI Y, EBERHART R. A modified particle swarm optimizer[C]. 1998 IEEE International Conference on Evolutionary Computation Proceedings. IEEE World Congress on Computational Intelligence (Cat. No. 98TH8360), 1998: 69-73.

作者简介



覃玉红,2017年于湖南大学获得学士学位,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: 13278855766@163.com

Qiu Yuhong received his B.Sc. degree from Hunan University in 2017. He is currently a master student at Hunan University. His main research interests include reliability and intelligent control and instrument.



唐求(通信作者),分别于1995年和2010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,主要研究方向为电能质量检测。

E-mail: tangqiu@hnu.edu.cn

Tang Qiu (Corresponding author) received her M.Sc. and Ph.D. degrees both from Hunan University in 1995 and 2010, respectively. She is currently a professor and a Ph.D. advisor at Hunan University. Her main research interest is electric energy quality detection.