

考虑多因素的电子式电压互感器误差 组合预测方法研究

钟悦^{1,2}, 李振华^{1,2}, 兰芳²

(1.三峡大学梯级水电站运行与控制湖北省重点实验室,湖北宜昌 443002;2.三峡大学电气与新能源学院,湖北宜昌 443002)

摘要:电子式电压互感器的测量准确度与电网的安全性和经济性有着紧密的联系。为准确地预测 EVT 长期运行过程中的误差,提出一种考虑多种因素的组合预测方法。该方法通过相关性分析选取与 EVT 误差相关性较强的参量作为特征量,分别使用融合注意力机制的 LSTM 模型与 SVR 模型对互感器的误差进行预测,随后将所得的各预测结果进行组合以得到最终的预测结果。对某变电站实时运行数据进行仿真分析,结果表明所提出的方法能够有效预测 EVT 在未来一段时间内的误差变化信息,对变电站及时预知 EVT 误差问题并安排进行计量性能检修具有一定的参考价值。

关键词:电子式电压互感器;误差预测;注意力机制;LSTM;SVR

DOI:10.19781/j.issn.1673-9140.2023.03.021 中图分类号:TM451 文章编号:1673-9140(2023)03-0188-09

Research on combined error prediction method of electronic voltage transformer considering multiple features

ZHONG Yue^{1,2}, LI Zhenhua^{1,2}, LAN Fang²

(1.Hubei Provincial Key Laboratory for Operation and Control of Cascaded Hydropower Station, China Three Gorges University, Yichang 443002, China; 2.College of Electrical Engineering and New Energy, China Three Gorges University, Yichang 443002, China)

Abstract: The measurement accuracy of electronic voltage transformer (EVT) is closely related to the security and economy of the power grid. In order to accurately predict the error of EVT during the long-term operation, a combined error prediction method considering multiple features is proposed. This method selects parameters with strong correlation to EVT errors through correlation analysis as feature quantities. It utilizes a fused attention mechanism LSTM model and an SVR model to predict the errors of the transformer separately. The obtained prediction results are then combined to generate the final prediction result. The real-time operational data of a certain substation is simulated and analyzed. The results indicate that the proposed method can effectively predict the error variation information of the EVT over a certain period of time and has certain reference value for the timely prediction of EVT errors in substations and scheduling of measurement performance maintenance.

Key words: electronic voltage transformer; error prediction; attention mechanism; LSTM; SVR

收稿日期:2022-03-18;修回日期:2022-10-15

基金项目:湖北省教育厅重点项目(D20201203);国家自然科学基金(51877122)

通信作者:李振华(1986—),男,博士,教授,主要从事电力设备状态监测与故障诊断、电能计量研究;E-mail:lizhenhua1993@163.com

智能电网的建设为助力中国实现碳达峰、碳中和目标具有重要意义。近些年来,中国电力网建设加速推进,变电站中各种电力设备的性能也相应有了更高的标准。保证电力设备的安全稳定、经济高效运行成为了完善电力系统配置的强大支持力量。

电压互感器是可以测量系统电压的电力测量设备,在变电站乃至整个电力系统中必不可少^[1-2]。但互感器现场运行环境复杂,易受周围磁场、温度等因素的影响,长期稳定性较差,不可避免地出现计量误差,无论是对电网的经济性还是安全稳定运行来说都会带来一定的潜在威胁。因此,电压互感器的误差预测对保护设备和保证互感器维持较高的测量准确性显得尤为重要^[3]。

过去的离线校验方式需要线路停电,操作不够便捷,且无法满足设备日益严格的检修评定要求。随着电网的智能化发展,互感器误差预测与评估领域逐渐趋向于在线方法研究。文献[4]通过对传递熵和小波神经网络进行研究,应用传递熵选取影响计量误差的主要参量,再进一步利用小波神经网络实现互感器的误差预测,但该方法的评价准确度易受到传感器精度的影响;文献[5]提出一种基于现场信号仿真技术的评估方法,研究样本提取自现场实际运行波形库,利用波形库中的特征波形对互感器进行误差测试,但该方法受现场环境的影响较大;文献[6]对高维随机矩阵理论进行深入探讨,提出一种通过构建评估矩阵得到评价指标和特征值,从而进一步进行互感器误差评估的方法,该方法可以实时确定多个环境因素对互感器误差状态的影响程度大小,但目前为止在线监测设备完善且实时数据丰富的变电站尚未普及,因而该方法的应用还无法广泛开展。文献[7]提出一种基于递推主元分析原理的评估方法,该方法首先进行离线学习建立主元分析模型,再进一步将得出的Q统计量与控制阈值相比较,以评估互感器的计量误差状态,达到判断互感器异常状态的目的。但分析结果表明此方法用Q统计量来反映误差状态的变化包含一定的偏差。

随着电力测量设备在线监测技术的进步,互感器实时运行数据日益增多,利用大数据技术对设备进行分析以评估设备实时运行状态并预测其运行

趋势成为新的研究热点^[8]。针对现有的电子式互感器误差预测精度低、稳定性不足、可实施性差的问题,本文利用电子式电压互感器(electronic voltage transformer, EVT)历史运行数据,借助数据挖掘的方法及深度学习网络,提出利用融合注意力机制的长短期记忆网络(long short-term memory, LSTM)和支持向量回归(support vector regression, SVR)进行EVT误差组合预测的方法。在拥有大量历史数据的情况下,该方法首先通过皮尔逊相关性分析充分挖掘数据的相关性,识别EVT误差的主要和次要影响因素,选取其中的主要影响因素作为预测模型的输入特征,并借助注意力机制进一步突出影响EVT比差及角差的关键信息;随后结合EVT实际运行数据,构建单输出变量和多输入变量模型,利用LSTM和SVR分别得出EVT比差及角差的预测值,将各自的预测结果进行组合以获取EVT比差及角差变化的特征和趋势。研究表明,该方法可有效实现对0.2级EVT误差变化趋势的预测。

1 基本模型

1.1 LSTM神经网络模型

分析处理时间序列数据常利用神经网络,其中应用较广泛的有循环神经网络(recurrent neural network, RNN)。为了解决长序列在模型训练过程中存在的梯度消失、梯度爆炸难题, LSTM神经网络应运而生,它具有同时记忆长、短期信息的能力^[9-10]。LSTM模型的典型结构如图1所示。LSTM拥有短期记忆通道,长期记忆通道以及遗忘门、输入门、输出门3种“门”结构,信息的选择性筛

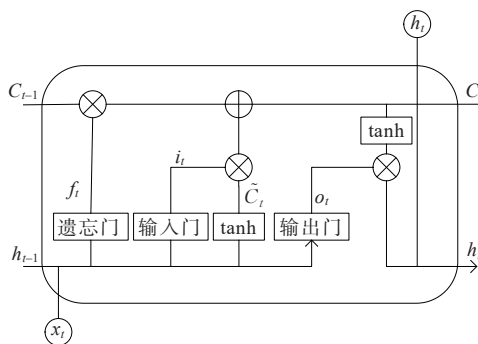


图1 LSTM网络结构

Figure 1 Structural diagram of LSTM network

选功能正是通过“门”结构来实现的^[11]。LSTM的工作原理如下:

1) 遗忘门输入前一时刻的输出数据及当前时刻的输入数据,选择需要保留的信息作为输出 f_i ;

2) 输入门处理得到输出信息 i_t , Sigmoid函数完成权重的更新及确定, tanh层保存备选内容 \tilde{C}_t ; 神经元细胞状态的输入为 i_t 与 \tilde{C}_t 相乘的结果, 遗忘门的输出 f_i 与此输入互相结合, 完成细胞状态的更新, 得到在 t 时刻细胞 C 的最终状态 C_t ;

3) 输出门将上一时刻的数据与当前输入相结合, 得到原始输出 o_t , tanh层将细胞状态 C_t 与 o_t 相乘, 得到最终的细胞输出结果 h_t 。

1.2 支持向量回归

支持向量机(support vector machine, SVM)是一种常用的机器学习算法, SVR则在此基础上衍生而来^[12], 通常利用回归函数来研究支持向量回归问题^[13]:

$$y = f(x) = \omega\phi(x) + b \quad (1)$$

其中, x_i, y_i 为平面 R_m 上某点的坐标, ω 为 m 维权值向量系数, b 为偏移项。

引入结构风险函数为

$$R_{\text{reg}} = \frac{1}{2} \|\omega\|^2 + c \cdot R_{\text{emp}}^{\epsilon} f(x) \quad (2)$$

其中, $\|\omega\|^2$ 用于描述函数, $f(x)$ 为复杂程度, c 为惩罚系数。不敏感损失函数又可以表示为

$$\hat{f}(x, \omega) = \begin{cases} |y - \hat{f}(x, \omega)|_{\epsilon} \\ 0, |y_i - \hat{f}(x, \omega)|_{\epsilon} \\ |y_i - \hat{f}(x, \omega)| - \epsilon, \text{ else} \end{cases} \quad (3)$$

其中, ϵ 为不敏感损失系数, 它是决定支持向量数目的重要因素, 同时还对模型的推广能力有影响, else是函数不收敛时损失函数的表达式。

给SVR引入径向基核函数^[14], 其表达式为

$$K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2) \quad (4)$$

其中, γ 为核函数的参数。 γ, ϵ 及 c 往往是影响SVR预测模型性能的主要因素。通过选择合适的参数, 可以使SVR取得良好的预测效果。

1.3 时序注意力机制

时序注意力机制(Attention)是基于人脑注意力作用的神经网络模型。在记忆大量信息时, 注意力

机制可以自动判别输入信息的重要程度, 对关键信息进行重点记忆, 而对重要性不高的信息加以忽略, 减弱其对目标任务的影响, 提高模型的训练效率^[15-16]。

EVT运行过程中不同环境参量对其误差预测结果的作用情况不同, 且具备一定的时空关联特征。为充分利用互感器的历史信息和未来信息, 本文通过引入时序注意力机制, 在LSTM预测模型输入层实现对不同特征重要程度的自动判别并分配不同的权重系数, 以突出影响EVT误差的关键信息。由此获取预测模型输入时序特征加权项, 从而对重要时刻的特征信息进行二次选取, 以提高模型预测精度。

2 EVT误差组合预测方法研究

2.1 EVT计量误差分析

电子式互感器是一次电网和二次控制系统之间相互联结的枢纽, 它将电网的一次电压信号转变成二次系统的数字电压信号, 为控制、计量及保护系统获取准确的电压信息提供相应的支持^[17]。

正常情况下, EVT的真实电压值与其二次侧测量数据之间难以避免地会呈现出微小的偏差, 但该微小的偏差值不会对计量数据带来较大的影响, 一般都在相应的精度要求范围之内。EVT整体误差大致可以分为随机误差和系统误差两大类, 通常前者由系统噪声引起, 后者来源于EVT本身的性能结构影响^[18]。EVT物理网络模型可表示为

$$u_s = kB_s + v_s + s_x + f_s \quad (5)$$

式中, u_s 为EVT的二次侧电压测量数据; k 为EVT的变比系数; B_s 为一次侧电压信号的真实值; v_s, s_x, f_s 分别为噪声误差、系统自有误差及EVT自身存在异常时的测量误差。

绝大多数情况下, 用比差和角差来描述EVT的计量误差, 表达式如下:

$$f\% = \frac{K_r U_2 - U_1}{U_1} \times 100\% \quad (6)$$

$$\delta = \varphi_2 - \varphi_1 \quad (7)$$

式(6)、(7)中, $f\%$ 为比差; δ 为角差; K_r 为EVT的一次电压额定值与二次电压额定值之比; U_1 为一次侧

电压信号的真实值; U_2 为二次侧输出电压的有效值; φ_1 、 φ_2 为相同时间时的一次、二次电压相位。

变电站运行环境复杂, EVT 由大量的电子单元组成, 在电网负荷、环境温度、湿度、电场、磁场、振动、谐波等多种因素的交叉作用影响下, 会发生电、热、湿环境老化^[19], 性能逐渐呈现弱化趋势, 导致 EVT 的计量偏差递增。一个或多个变量数据发生变化, 均可以使 EVT 的输出呈现较显著的变化, 进一步直接影响到 EVT 的比差、角差值。因此, 针对 EVT 长期运行稳定性差、测量不准确的问题, 需要对 EVT 的计量误差变化趋势进行预测。

借助于单输出变量和多输入变量模型, 能够对 EVT 计量误差进行相应的描述。本文将比差及角差作为模型的输出, 输入则为互感器运行现场的多种影响因素, 即

$$f\% = f_1(x_1, x_2, x_3, \dots) \quad (8)$$

$$\delta = f_2(x_1, x_2, x_3, \dots) \quad (9)$$

其中, x_1 、 x_2 、 x_3 等为负荷、温度、磁场等参量。在互感器运行现场, EVT 的误差数据以及误差影响量数据均可以采集得到。测量数据反映着互感器数据信息间的关联性, 利用以上模型, 可以表征互感器比差、角差与各种参量之间的联系, 预测 EVT 误差变化趋势。

2.2 输入特征选择

由于 EVT 在实际运行中, 条件较为复杂, 影响 EVT 误差的关键参量通常为运行现场的温度、湿度、磁场、振动及负荷等因素。利用皮尔逊相关性分析对采集到的数据样本进行处理, 来选择对 EVT 误差相关性较大的影响因素, 作为模型的输入变量。得到的温度、湿度、负荷、振动、磁场对 EVT 比差及角差的相关系数值, 如表 1 所示。

表 1 相关系数值

Table 1 Correlation coefficient value

映射关系	相关系数	映射关系	相关系数
温度—比差	0.589 0	温度—角差	-0.445 5
湿度—比差	-0.502 2	湿度—角差	0.177 5
负荷—比差	-0.341 0	负荷—角差	0.050 0
振动—比差	0.161 4	振动—角差	-0.138 8
磁场—比差	-0.002 9	磁场—角差	0.030 9

相关系数值直接反映了两变量的相关性大小, 相关系数值越接近于 0, 表示两者关系趋于零相关, 相关系数值越接近于 1 或 -1, 表示两者之间相关性越强。根据表 1 结果, 磁场与比差、角差的相关性始终保持在较弱水平, 故主要考虑温度、湿度、振动、负荷对 EVT 比差及角差的影响, 将这几种参量作为预测模型的输入, 间接表征 EVT 误差特性。

2.3 模型构建

单一的 LSTM 网络可以有效地利用数据的时序性特征, 但分析原始数据关联性的能力不足。时序注意力机制可以充分挖掘并利用数据的时序相关性。SVR 具有很强的学习能力, 泛化能力较为优秀, 并且可以较容易地在拟合程度与泛化水平上取得平衡^[20]。因此, 本文通过构建组合预测模型将时序注意力机制、LSTM 模型与 SVR 模型的优点结合, 从而达到更好的预测效果。

组合预测的基本思路: 分别采用引入注意力机制的 LSTM 模型与 SVR 模型对 EVT 的比差及角差进行预测, 得到各自的预测值; 随后利用标准差法得到以上 2 种模型的权重系数; 进而依据此权重系数将 2 种模型进行加权组合, 得到最终的预测结果, 将模型简称为 ALS (Attention-LSTM-SVR)。ALS 组合模型预测示意如图 2 所示。

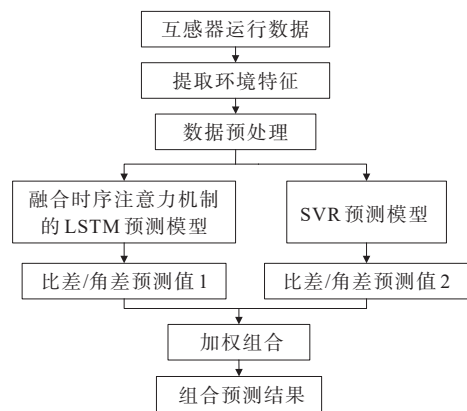


图 2 组合模型预测示意

Figure 2 Schematic diagram of combined model prediction

实现预测功能的主要步骤如下。

1) 特征选择。模型的输出变量为 EVT 的比差和角差 2 种误差描述量; 按文 2.2 所述方法选取模型的输入变量为温度、湿度、振动、负荷; 按比例将数据样本划分为训练集与测试集。

2) 数据处理。为解决各输入变量及各输出变

量的量纲和单位均不同而影响预测结果准确度的问题,采用最大-最小归一化法对模型的输入变量和输出变量数据进行归一化处理,具体方法如下:

$$x_i' = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (16)$$

其中, x_i 为待归一化处理的原始数据, x_{\max} 、 x_{\min} 分别表示原始数据集中的最大值与最小值, x_i' 为归一化后的数据,其取值范围为 $-1 \sim 1$ 。

3) 预测。组合预测需要分别求出各个模型的预测值与其相应权重的乘积,再进一步将各模型得到的值进行求和得到总体值,除以相应的模型个数得到的最终值即为组合模型的预测值。结合已采集的数据样本,将选取的4种特征参量分别引入注意力机制层及SVR模型的输入层。前者进行重要特征的二次提取后,输出到LSTM预测模型的输出层作为输入,进行相应的计算后,输出LSTM模型的预测值;后者则直接输出SVR模型的预测值。

各个预测模型权重系数的设置是构建模型的关键环节^[21],也是影响组合模型预测准确度的主要因素。本文在确定权重系数大小时考虑使预测误差的平方和达到最小的原则,表达式如下:

$$\begin{cases} \min E = \sum_{i=1}^n (x_i - \sum_{k=1}^K \omega_k \tilde{x}_{ik})^2 \\ \text{s.t. } \sum_{k=1}^K \omega_k = 1, \omega_k \geq 0, k = 1, 2, \dots, K \end{cases} \quad (10)$$

在求得各模型权重大小的基础上,本文采用加权平均法将引入注意力机制的LSTM模型及SVR模型结合起来构建组合模型,表达式如下:

$$V_{\text{ALS}} = \frac{W_{\text{SVR}} \cdot V_{\text{SVR}} + W_{\text{LSTM}} \cdot V_{\text{LSTM}}}{2} \quad (11)$$

其中, V 为模型预测值, W 为权重系数。由于各个样本的情况不同,在不同样本的预测过程中融合注意力机制的LSTM模型及SVR模型各自的权重大小也有所不同。对于模型权重系数的确定,本文采用的是标准差衡量的方法^[22],引入标准差可以较好地衡量序列数据的波动情况。方法如下列公式所示:

$$W_{\text{SVR}} = \left(1 - \frac{S_{\text{VRdiff}}}{L_{\text{diff}} + S_{\text{VRdiff}}}\right) \times 2 \quad (12)$$

$$W_{\text{LSTM}} = 2 - W_{\text{SVR}} \quad (13)$$

$$S_{\text{VRdiff}} = S_{\text{std}} - S_{\text{VRstd}} \quad (14)$$

$$L_{\text{diff}} = S_{\text{std}} - L_{\text{std}} \quad (15)$$

其中, S_{std} 、 S_{VRstd} 、 L_{std} 分别为样本、SVR模型预测结果、融合注意力机制的LSTM模型预测结果的标准差。采用加权平均的方法,即可获得组合模型的比差、角差预测结果。

2.4 模型评估指标

为了方便直观地对模型的预测效果进行衡量和评估,采用平均绝对误差 M_{AE} 、平均绝对百分误差 M_{APE} 以及均方根误差 R_{MSE} 这3个指标来评定模型的预测结果。 M_{AE} 具有准确反映实际预测误差的功能,能够解决误差相互抵消的问题; M_{APE} 既能良好地反映预测值与真实值间的偏差,也能反映两者的比例关系; R_{MSE} 则可以反映模型的稳定性^[23-24]。表达式如下:

$$M_{\text{AE}} = \frac{1}{N} \sum_{i=1}^N |Y_{\text{py}} - Y_{it}| \quad (17)$$

$$M_{\text{APE}} = \frac{1}{N} \sum_{i=1}^N \frac{|Y_{\text{py}} - Y_{it}|}{Y_{\text{py}}} \times 100\% \quad (18)$$

$$R_{\text{MSE}} = \sqrt{\frac{1}{N} \sum_{i=1}^N (Y_{\text{py}} - Y_{it})^2} \quad (19)$$

式中, Y_{py} 为样本真实值; Y_{it} 为预测值; N 为样本个数。3种评估指标值的大小表现了模型的预测效果,其值均越小越好。

3 仿真实验验证

为了充分说明所提出的ALS组合预测模型预测EVT误差的有效性,本文采集某变电站EVT的在线监测数据及环境数据作为数据样本,对其比差、角差分别进行预测。并将ALS组合预测模型的预测结果与采用BP神经网络、SVM的预测结果进行对比。

本文的实验环境由Windows 10、64位操作系统组成,基于Matlab R2018a实现。LSTM网络的偏置项和输出层偏置项初始化为0,LSTM隐藏层数设置为200,迭代次数设置为350,为防止梯度爆炸,将梯度阈值设置为1,初始化权重 $[-0.5, 0.5]$,指定初始学习率为0.005。SVR模型选用径向基核函数,惩罚系数 c 的取值范围为 $[2^{-5}, 2^5]$,核函数参数 γ 的取值范围为 $[10^{-5}, 10^5]$, ϵ 的取值范围为

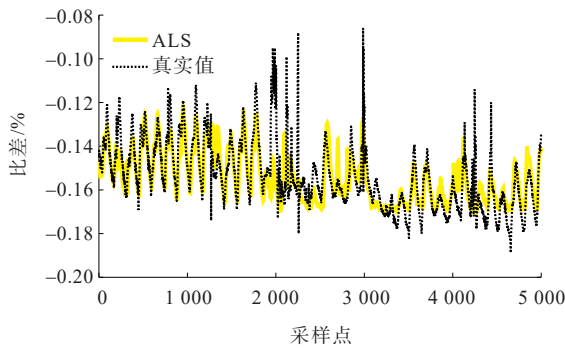
[$10^{-5}, 10^2$],通过交叉验证寻找最佳参数训练模型。

3.1 数据来源

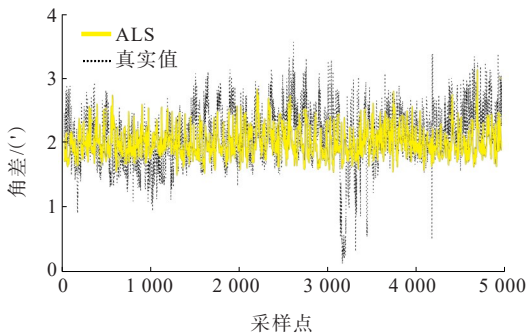
本文主要探讨影响因素在 0.2 级 EVT 未超越限值的正常工况下对误差的影响,所利用的 EVT 误差数据和环境监测数据采集自某变电站 0.2 级 A 相 EVT 在 2016 年 8 月至 10 月期间的在线实时运行数据,获取的数据包括温度、湿度、负荷、振动、磁场及 EVT 比差、角差数据。每 10 min 采集一次数据,共计近一万组数据。数据采集过程符合相关规定,数据完整性和准确性良好。比差和角差数据的获取,由 0.05 级的电压互感器作为标准互感器与被测互感器并列运行^[25],实时对比计算后得出。负荷数据于变电站监控室获取。利用所采集的数据建立 EVT 误差预测模型,选择这组数据的前 40% 作为训练数据集,其余作为测试数据集,并将测试集的后 5 000 组数据得到的预测结果输出,用来对模型的预测效果进行验证。

3.2 预测结果分析

利用 ALS 组合模型进行训练和预测,得到 EVT 比差、角差的预测结果如图 3 所示。



(a) 比差预测结果



(b) 角差预测结果

图 3 基于组合模型的 EVT 误差预测结果

Figure 3 Error prediction result of EVT based on combined model

为验证本文所选参量的重要性和有效性,设置对比数据集,如表 2 所示。

表 2 数据集输入特征选取

Table 2 Input feature selection of data set

数据集	特征输入量选取
原始	温度、湿度、振动、负荷
对比	温度、湿度、磁场

输入不同误差影响参量,建立基于 ALS 组合模型的比差、角差预测模型,由原始数据集和对比数据集得到的 EVT 误差预测效果评估指标结果如表 3 所示。由评估指标结果可以看出,温度、湿度、振动、负荷数据组成的原始数据集相比于温度、湿度、磁场组成的对比数据集而言,其 M_{AE} 、 M_{APE} 、 R_{MSE} 均处于更低值。由此可见,原始数据集所选取的特征参量与 EVT 比差、角差的相关性较强,可以间接反映 EVT 的计量误差,作为模型输入的预测效果更好。

表 3 各数据集预测误差对比


Table 3 Prediction error comparison of each data set

ALS 模型	M_{AE}	$M_{APE}/\%$	R_{MSE}	
比差	原始数据集	0.006 4	4.46	0.009 7
	对比数据集	0.009 3	4.75	0.017 4
角差	原始数据集	0.017 6	6.74	0.019 3
	对比数据集	0.020 8	7.97	0.051 8

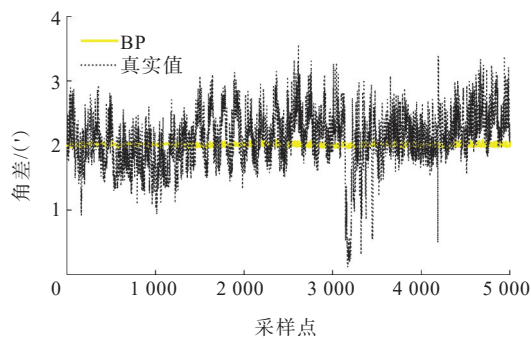
为进一步体现 ALS 模型的预测效果,分别使用 BP 神经网络模型和 SVM 模型进行 EVT 比差、角差预测作为对比,预测结果分别如图 4、5 所示;ALS 组合预测模型、SVM 模型及 BP 神经网络模型预测比差、角差的效果评估指标结果如表 4、5 所示。

对比各预测方法预测值曲线与真实值曲线以及表 4、5 中评估指标的值,显然 ALS 组合预测模型的预测曲线更贴近于真实值曲线,且其模型的 M_{AE} 、 M_{APE} 、 R_{MSE} 评估指标值更低,因此它能够较好地实现对 EVT 比差和角差的预测。

综上所述,ALS 模型、BP 神经网络模型和 SVM 模型都能够实现对 EVT 的比差、角差进行预测,但预测特点各有不同,预测结果也呈现出较大差异。该文提出的 ALS 组合预测模型相对而言预测误差分布更贴合实际情况,评估指标也证实此方法的预测精度更高,总体上预测性能更佳。

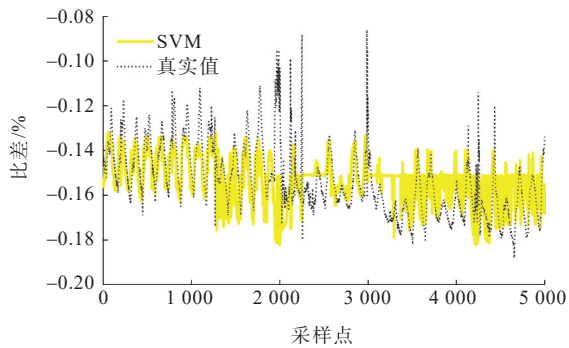


(a) 比差预测结果

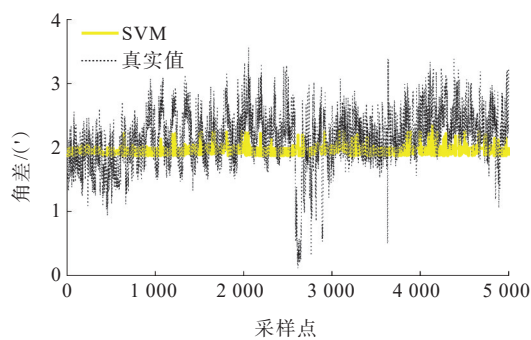


(b) 角差预测结果

图4 基于BP神经网络的EVT误差预测结果
Figure 4 Error prediction result of EVT based on BP neural network



(a) 比差预测结果



(b) 角差预测结果

图5 基于SVM模型的EVT误差预测结果
Figure 5 Error prediction result of EVT based on SVM model

表4 比差评估效果对比

Table 4 Comparison of the evaluation effect of ratio difference

预测方法	M_{AE}	$M_{APE}/\%$	R_{MSE}
ALS	0.006 4	4.46	0.009 7
BP	0.008 7	4.47	0.011 8
SVM	0.011 1	7.57	0.015 2

表5 角差评估效果对比

Table 5 Comparison of the evaluation effect of angle difference

预测方法	M_{AE}	$M_{APE}/\%$	R_{MSE}
ALS	0.017 6	6.74	0.019 3
BP	0.019 8	6.83	0.023 7
SVM	0.023 1	8.33	0.487 1

基于以上分析,本文所提出的 ALS 误差预测模型可以有效地将各种影响参量与 EVT 比差及角差之间的关系联结起来。在变电站实际运行过程中,基于此模型和 EVT 庞大的历史运行数据,可以预知未来一段时间内的 EVT 误差变化信息,以便于及时发现并处理 EVT 误差问题。当预测到 EVT 在将来某个时刻可能出现误差超差的情况时,则可以安排工作人员进行 EVT 计量性能检修及修正,还可以为现场工作人员给互感器提供更好的运行环境提供参考。

4 结语

针对电子式互感器长期运行过程中稳定性下降,从而影响到电力量计准确度的问题,提出了一种综合时序注意力机制、LSTM 神经网络及 SVR 的 EVT 误差状态评估方法。该方法通过相关性分析筛选出 EVT 运行过程中对误差影响相对较大的特征参量,利用单输出变量和多输入变量模型将融合注意力机制的 LSTM 模型与 SVR 模型进行组合以实现 EVT 比差、角差的预测。与广泛采用的 BP 神经网络模型及 SVM 模型相比,多个评估指标均表现出文中所提出的模型具备更优异的预测性能,能够根据历史运行数据有效地预测 EVT 的计量误差状态,为变电站的设备运维工作提供一定的依据,给互感器提供更好的运行环境提供参考,以维护电力系统的科学稳定运行,减少经济损失。

参考文献:

[1] 宋晓林,刘浩,刘豪,等.500/3^{1/2} kV 0.002 级多级励磁标

- 准电压互感器设计与仿真分析[J].电工技术学报,2021,36(9):1967-1975.
- SONG Xiaolin,LIU Hao,LIU Hao,et al.Simulation analysis and design of 500/3^{1/2} kV 0.002 multistage excitation standard voltage transformer with accuracy class 0.002[J]. Transactions of China Electrotechnical Society, 2021, 36(9):1967-1975.
- [2] 张有锋,郑运鸿,戴冬云,等.温度对电子式电压互感器测量精度的影响研究[J].高压电器,2022,58(6):221-227. ZHANG Youfeng,ZHENG Yunhong,DAI Dongyun,et al. Research on influence of temperature on metering accuracy of electronic voltage transformer[J].High Voltage Apparatus, 2022,58(6): 221-227.
- [3] 李永森.电容式电压互感器误差特性影响因素研究[D].重庆:重庆大学,2016. LI Yongsen.Study on the influence factors on the error characteristics of the capacitor voltage transformer[D]. Chongqing:Chongqing University,2016.
- [4] 李振华,郑严钢,李振兴,等.基于传递熵和小波神经网络的电子式电压互感器误差预测[J].电测与仪表,2021,58(3):146-152. LI Zhenhua,ZHENG Yangang,LI Zhenxing,et al. Error prediction of electronic voltage transformer based on transfer entropy and wavelet neural network[J].Electrical Measurement & Instrumentation,2021,58(3):146-152.
- [5] 海宾,杨姝楠,陈丽雯,等.基于现场信号仿真技术的电流互感器误差测试技术研究[J].电测与仪表,2021,58(2):133-138. HAI Bin,YANG Shunan,CHEN Liwen,et al.Research on current transformer error testing technology based on field signal simulation technology[J].Electrical Measurement & Instrumentation,2021,58(2):133-138.
- [6] 胡琛,张竹,焦洋,等.基于随机矩阵理论电子式互感器误差状态相关性分析方法[J].电力自动化设备,2018,38(9):45-53. HU Chen,ZHANG Zhu,JIAO Yang,et al. Error state correlation analysis based on random matrix theory for electronic transformer[J]. Electric Power Automation Equipment,2018,38(9):45-53.
- [7] 韩海安,张竹,王晖南,等.基于主元分析的电容式电压互感器计量性能在线评估[J].电力自动化设备,2019,39(5):201-206. HAN Hai'an,ZHANG Zhu,WANG Huinan,et al. Online metering performance evaluation of capacitor voltage transformer based on principal component analysis[J]. Electric Power Automation Equipment, 2019, 39(5): 201-206.
- [8] 严英杰,盛戈峰,王辉,等.基于高维随机矩阵大数据分
- 析模型的输变电设备关键性能评估方法[J].中国电机工程学报,2016,36(2):435-445.
- YAN Yingjie,SHENG Gehao,WANG Hui,et al.The key state assessment method of power transmission equipment using big data analyzing model based on large dimensional random matrix[J]. Proceedings of the CSEE, 2016,36(2):435-445.
- [9] 罗龙,李两桓,王成阳,等.基于ARIMA-LSTM的绝缘子状态数据挖掘方法[J].电力科学与技术学报,2017,32(4):38-43. LUO long,LI Lianghuan,WANG Chengyang,et al. Insulator status data mining method based on ARIMA-LSTM[J]. Journal of Electric Power Science and Technology,2017, 32(4):38-43.
- [10] 刘亚琤,赵倩.基于聚类经验模态分解的CNN-LSTM超短期电力负荷预测[J].电网技术,2021,45(11):4444-4451. LIU Yahui,ZHAO Qian. Ultra-short-term power load forecasting based on cluster empirical mode decomposition of CNN-LSTM[J]. Power System Technology,2021,45(11):4444-4451.
- [11] 陈自强.基于LSTM网络的设备健康状况评估与剩余寿命预测方法的研究[D].合肥:中国科学技术大学,2019. CHEN Ziqiang.research on equipment health assessment and remaining useful life prediction method based on LSTM[D]. Hefei: University of Science and Technology of China,2019.
- [12] 张运厚,李婉莹,董福贵.基于DE-GWO-SVR的中长期电力需求预测[J].中国电力,2021,54(9):83-88. ZHANG Yunhou,LI Wanying,DONG Fugui,et al. Medium and long-term power demand forecasting based on DE-GWO-SVR[J].Electric Power,2021,54(9):83-88.
- [13] 李梦涵,赵学文,李建琦,等.基于VMD-SVM的小电流接地系统故障选线方法[J].电网与清洁能源,2021,37(8):1-8. LI Menghan,ZHAO Xuewen,LI Jianqi,et al. Fault line selection method for small current grounding system based on VMD-SVM[J].Power System and Clean Energy, 2021, 37(8): 1-8.
- [14] 吴海涛,代尚林,乔中伟,等.基于RBF-SVM智能配变终端的网络安全态势评估[J].电力科学与技术学报,2021,36(5):35-40. WU Haotao,DAI Shanglin,QIAO Zhongwei,et al. Research on network security situation awareness of intelligent distribution transformer terminal unit based on RBF-SVM [J]. Journal of Electric Power Science and Technology, 2021,36(5):35-40.
- [15] 李卓,叶林,戴斌华,等.基于IDSCNN-AM-LSTM组合神

- 经网络超短期风电功率预测方法[J]. 高电压技术, 2021, 48(6): 2117-2127.
- LI Zhuo, YE Lin, DAI Binhua, et al. Ultra-short-term wind power prediction method based on IDSCNN-AM-LSTM combination neural network[J]. High Voltage Engineering, 2021, 48(6): 2117-2127.
- [16] 朱凌建, 荀子涵, 王裕鑫, 等. 基于 CNN-Bi LSTM 的短期电力负荷预测[J]. 电网技术, 2021, 45(11): 4532-4539.
- ZHU Lingjian, XUN Zihan, WANG Yuxin, et al. Short-term power load forecasting based on CNN-BiLSTM[J]. Power System Technology, 2021, 45(11): 4532-4539.
- [17] 胡浩亮, 李前, 卢树峰, 等. 电子式互感器误差的两种校验方法对比[J]. 高电压技术, 2011, 37(12): 3022-3027.
- HU Haoliang, LI Qian, LU Shufeng, et al. Comparison of two electronic transformer error measuring methods[J]. High Voltage Engineering, 2011, 37(12): 3022-3027.
- [18] 唐登平, 蔡文嘉, 周翔宇, 等. 基于 VMD 和样本熵的电磁式电流互感器故障诊断[J]. 电力科学与技术学报, 2021, 36(6): 144-150.
- TANG Dengping, CAI Wenjia, ZHOU Xiangyu, et al. Fault diagnosis of current transformer based on VMD and sample entropy[J]. Journal of Electric Power Science and Technology, 2021, 36(6): 144-150.
- [19] 张竹. 电容式电压互感器计量误差状态评估和预测方法研究[D]. 武汉: 华中科技大学, 2018.
- ZHANG Zhu. Research on condition evaluation and prediction methods for the metering error of capacitor voltage transformer[D]. Wuhan: Huazhong University of Science and Technology, 2018.
- [20] 刘季昂, 刘友波, 邱高, 等. 基于高斯过程回归的电网运行方式快速置信评价[J]. 电力系统自动化, 2022, 46(11): 181-190.
- LIU Ji'ang, LIU Youbo, QIU Gao, et al. Fast confidence evaluation of operation mode of power grid based on gaussian process regression[J]. Automation of Electric Power Systems, 2022, 46(11): 181-190.
- [21] 刘军, 王苗, 严清心, 等. 基于组合赋权和梯形云模型的发电商市场力评价[J]. 电力科学与技术学报, 2021, 36(2): 58-66.
- LIU Jun, WANG Miao, YAN Qingxin, et al. Market power evaluation of generators based on combination weighting and trapezoidal cloud model[J]. Journal of Electric Power Science and Technology, 2021, 36(2): 58-66.
- [22] 吴少聪. 基于混合模型的股票趋势预测方法研究[D]. 哈尔滨: 哈尔滨工业大学, 2017.
- WU Shaocong. Research on methods of stock trends prediction based on hybrid model[D]. Harbin: Harbin Institute of Technology, 2017.
- [23] 熊一, 詹智红, 柯方超, 等. 基于改进 BP 神经网络的变电站检修运维成本预测[J]. 电力科学与技术学报, 2021, 36(4): 44-52.
- XIONG Yi, ZHAN Zhihong, KE Fangchao, et al. Overhaul operation and maintenance cost prediction of substation based on improved BP neural network[J]. Journal of Electric Power Science and Technology, 2021, 36(4): 44-52.
- [24] 张帅可, 罗萍萍. 基于混合分布模型的风电功率超短期预测误差分析[J]. 电力科学与技术学报, 2020, 35(5): 111-118.
- ZHANG Shuaike, LUO Pingping. Wind ultra short-time prediction error analysis of wind power based on mixed distribution model[J]. Journal of Electric Power Science and Technology, 2020, 35(5): 111-118.
- [25] LI Z H, LI H B, ZHANG Z, et al. An online calibration method for electronic voltage transformers based on IEC 61850-9-2[J]. Mapan-Journal of Metrology Society of INDIA, 2014, 29(2): 201497-105.

(上接第 187 页 = Continued from page 187)

- [17] 韩筛根, 朱孟周, 李玉凌, 等. 一二次融合配电开关的融合决策及故障诊断研究[J]. 高压电器, 2021, 57(2): 14-21.
- HAN Shaigen, ZHU Mengzhou, LI Yuling, et al. Study on fusion decision and fault diagnosis of primary and secondary fusion distribution switch[J]. High Voltage Apparatus, 2021, 57(2): 14-21.
- [18] YU L, SUN Y, LI K J, et al. An improved genetic algorithm based on fuzzy inference theory and its application in distribution network fault location[C]// 2016 IEEE 11th Conference on Industrial Electronics and Applications(ICIEA), Hefei, China, 2016.
- [19] 苗人杰, 刘玉林, 张利, 等. 基于多代理系统的含 DG 辐射状配电网故障定位[J]. 电网与清洁能源, 2021, 37(1): 8-15.
- MIAO Renjie, LIU Yulin, ZHANG Li, et al. A fault location algorithm in radial distribution networks with distributed generators based on multi-agent technology[J]. Power System and Clean Energy, 2021, 37(1): 8-15.
- [20] POURAHMADI-NAKHLI M, SAFAVI A A. Path characteristic frequency-based fault locating in radial distribution systems using wavelets and neural networks[J]. IEEE Transactions on Power Delivery, 2011, 26(2): 772-781.