

# 基于 Seasonal Hybrid ESD 算法的电力变压器噪声检测方法研究

罗浪<sup>1</sup>, 赵泽予<sup>1</sup>, 武晓蕊<sup>1</sup>, 杨丰帆<sup>1</sup>, 荣仪<sup>2</sup>

(1. 国网湖北省电力有限公司 超高压公司, 湖北 武汉 430050;

2. 南昌工程学院 电气工程学院, 江西 南昌 330099)

**摘要:** 为提高在实际仅有少量样本情形下的变压器时序数据异常检测正确率, 提出一种基于混合季节性极端偏差检验算法(Seasonal Hybrid ESD, S-H-ESD)的电力变压器噪声信号分析方法。首先通过 STL 将原始时序数据分解为长趋势、周期和残差分量, 再采用 S-H-ESD 检验残差分量中的异常, 将偏离中位数超出阈值的数据点作为变压器噪声信号的异常点, 实现原始噪声信号数据中的异常点定位, 最后通过对某 500 kV 变电站主变实测样本集数据, 将所提方法与 Prophet 方法进行对比试验, 结果表明: 所提方法在小样本数据下异常点检测正确率高达 99.67%, 为电力变压器运行状态噪声检测应用提供了小样本场景下的有效方法。

**关键词:** 电力变压器; 噪声信号; S-H-ESD 算法; 异常点检测; 小样本分析

中图分类号: TP183 文献标识码: A 文章编号: 1003-7241(2025)02-0105-05

## Research on Power Transformer Noise Detection Method Based on Seasonal Hybrid ESD Algorithm

LUO Lang<sup>1</sup>, ZHAO Ze-yu<sup>1</sup>, WU Xiao-rui<sup>1</sup>, YANG Feng-fan<sup>1</sup>, RONG Yi<sup>2</sup>

(1. Maintenance Company of State Grid Hubei Electric Power Co., Ltd., Wuhan 430050 China;

2. School of Electrical Engineering, Nanchang Institute of Technology, Nanchang 330099 China)

**Abstract:** In order to improve the accuracy of anomaly detection of transformer timing data when there are only a few samples in practice, this paper proposes a power transformer noise signal based on the Seasonal Hybrid ESD (Seasonal Hybrid ESD, SH-ESD) inspection algorithm. It analyses method to locate the abnormal collection point of the original noise signal. Based on the measured sample sets data of the main transformer of a 500 kV substation, the method in this paper is compared and analyzed with the Prophet method. The results show that the method has a high accuracy of 99.67% in detecting outliers in small sample data, which provides a method for the application of noise in the operating state of power transformers.

**Keywords:** power transformer; noise signal; S-H-ESD algorithm; abnormal point; small sample analysis

### 0 引言

变压器噪声水平的高低是衡量变压器的重要技术参数, 监测变压器噪声水平对设备状态评估和诊断具有实际意义<sup>[1-3]</sup>。对电力设备运行数据进行监测、诊断可以发现设备运行中的状态异常<sup>[4-5]</sup>。电力变压器本体噪声主要来源于磁通变化导致铁芯、绕组、油箱及冷却装置等收缩引起的振动, 其中铁芯振动占据主要部分。由于设备运行状态改变, 使电力变压器的噪声信号具有长期特征周期变化、短期无规则波动的特征, 短期波动特征表现在原始采集信号中是具有不和谐异常的特征数据。

当前已经有很多对变压器噪声信号分析的研究成果。运行在相同负载容量下的变压器噪声水平与谐波含

量水平具有正向相关性, 常通过控制谐波水平方法控制降低噪声<sup>[6]</sup>。采用声压法和声强法测定噪声, 通过经验模态将噪声信号分解, 可以为变压器故障识别提供特征数据<sup>[7]</sup>。通过变压器噪声的频谱特性发现, 正常负荷水平下噪声成分主要是中心频率是 100 Hz 低频噪声<sup>[8]</sup>。

本文在现有噪声分析基础上, 通过对变压器原始噪声信号波形进行研究, 发现噪声波形信号分析主要是时序数据异常检测问题, 时序数据中的异常点与正常点有较低的相似度, 很多算法通过相似度差异识别异常<sup>[9-10]</sup>。Prophet 模型是一种基于时间序列重构的方法, 可以比较重构序列与原始序列的差异定位异常<sup>[11-12]</sup>。现实通常是少量样本数据情况的异常检测问题, 需要采用无监督的异常检测方法<sup>[13-16]</sup>。同时为提高无监督算法检测模型鲁棒性, 采用多种方法结合的集成检测方法<sup>[17-19]</sup>。

因此, 文章针对仅有少量样本的时序数据异常检测

\*基金项目: 国家自然科学基金项目 (62001202)

收稿日期: 2023-07-13

问题,提出一种基于混合季节性的极端偏差检验算法(Seasonal Hybrid ESD,S-H-ESD)的电力变压器噪声信号分析方法:首先通过时间序列分解方法(Seasonal and Trend decomposition using Loess,STL)将原始时序数据分解为长趋势、周期和残差分量,再采用极端偏差检验算法(Extreme Studentized Deviate test,ESD)检验残差分量中的异常,将偏离均值超出阈值的数据点作为变压器噪声信号的异常点,从而完成原始噪声信号的异常定位。

## 1 方法基础

### 1.1 S-H-ESD算法

#### 1.1.1 时间序列分解算法

在介绍S-H-ESD方法之前,首先对其中需要涉及的鲁棒性加权的时间序列分解方法(Seasonal and Trend decomposition using Loess,STL)进行介绍,STL方法较传统序列分解方法而更加稳健,可以克服传统分解方法中非平缓趋势序列去除周期、趋势分量之后残余项陡坡的弊端。STL分解流程如表1中所示。

表1 STL分解整体流程

STL分解实现:	
外循环	计算鲁棒性权重;
	Step 1 去除序列长期趋势;
	Step 2 对周期子序列进行平滑;
内循环	Step 3 过滤低通量的周期子序列;
	Step 4 减去平滑处理后周期子序列趋势量;
	Step 5 减去周期量;
	Step 6 进行平滑趋势操作;

$$Y_N = T_N + S_N + R_N \quad N=1, \dots, n \quad (1)$$

STL通过局部加权回归能较好地解决具有趋势和周期特性序列的平滑问题,对单维时间序列数据 $\bar{Y}_N = \{y_1, y_2, \dots, y_n\}$ ,取 $y_i$ 作为中心点,前后各延展 $k/2$ 长度,对该段数据使用权值函数 $w$ 做加权线性回归,得到拟合后的值 $\bar{y}_i$ , $k$ 个数据点连线即为这段数据的局部加权回归线,具体执行过程如文献[20-21]。STL分解包括内循环与外循环流程,如式(1)中所示,将时序数据 $Y_N$ 分解为趋势项 $T_N$ 、周期项 $S_N$ 和残差项 $R_N$ 。

#### 1.1.2 改进季节性混合极端偏差检验算法

改进季节性混合极端偏差检验算法(S-H-ESD)是在极端偏差检验算法(Extreme Studentized Deviate test,ESD)基础上,使用中位数和绝对中位数替换原最大检验统计量 $R_j$ 中的均值项和标准差项以提高算法的鲁棒性,对经STL分解后得到的残余分量进行检测,将残差中最大检验统计量超过临界阈值的数据标记为异常数据点,并认为残差序列中此异常点对应原始序列数据点同样是异常数据。采用S-H-ESD方法进行异常点检验能有效提高对周期性变化、多峰分布数据异常检测问题准确度<sup>[22-23]</sup>。

S-H-ESD算法具体过程如下:

(1) 计算检验统计量。

$$G_i = \frac{|R_i - \bar{R}|}{s} \quad (2)$$

式中, $\bar{R}$ 为均值, $R_i$ 为第 $i$ 个数据点, $s$ 为残差序列标准差。当检验统计量满足以下条件时,数据存在异常点:

$$G_i > \frac{N-1}{\sqrt{N}} \sqrt{\frac{\left(\frac{t_{\alpha}}{2N}, N-2\right)^2}{N-2 + \left(\frac{t_{\alpha}}{2N}, N-2\right)^2}} \quad (3)$$

式中, $N$ 为数据集样本数量, $\frac{t_{\alpha}}{2N}, N-2$ 是显著度为 $\frac{\alpha}{2N}$ 、自由度为 $N-2$ 的 $t$ 分布临界值。

(2) 计算本次检验的最大检验统计量 $R_j$ 。

将检验统计量最大处数据点作为当前残差数据中的待检验量:

$$R_j = \frac{\max |R_i - \bar{R}|}{S} \quad (4)$$

使用中位数和绝对中位差替换式(4)中的均值与标准差,提高算法检验的鲁棒性,绝对中位差MAD和替换后新的 $R_j$ 为:

$$MAD = \text{median}(R_j - \text{median}(R)) \quad (5)$$

$$\left\{ R_j = \frac{\max |R_i - \text{median}(R)|}{MAD} \right. \quad (6)$$

$$1 \leq j \leq k$$

式中,MAD为残差分量序列的绝对中位差。

(3) 计算临界阈值 $\lambda_j$ 。

$$\left\{ \lambda_j = \frac{(n-j) \cdot t_{p,n-j-1}}{\sqrt{(n-j-1 + t_{p,n-j-1}^2)(n-j+1)}} \right. \quad (7)$$

$$1 \leq j \leq k$$

式中, $\lambda_j$ 为临界阈值, $t_{p,n-j-1}$ 表示自由度为 $n-j-1$ 、显著度为 $p$ 的 $t$ 分布临界值的平方项,其中 $p = 1 - \frac{\alpha}{2(n-k+1)}$ 。

(4) 比较本次最大检验统计量与临界阈值。

若 $R_j > \lambda_j$ ,则界定样本点为异常数据点。

(5) 移除异常点,进行下次检验。

## 1.2 检测评价指标

本文采用目标检测常用评价指标对S-H-ESD算法的检测结果进行分析,包括TP、FN、FP、TN四项基本指标,其中TP项表示的是实际是异常数据点,检测结果也是异常数据点的检测结果,是直观描述算法异常点检测效果好坏最关注的数据类型;FN项表示的是实际是异常数据点,但是检测结果是标记为正常数据点的检测结果;FP项表示的是实际是正常数据点,但是检测结果是标记

为异常数据点的检测结果;TN项是实际是正常数据点,检测结果也是正常数据点的检测结果。

在上述四项基本指标基础上,构建TPR、FPR、R、P、F、A等六项衍生指标,其构造关系为:

$$\begin{cases} TPR = \frac{TP}{TP + FN} \\ FPR = \frac{FP}{FP + TN} \\ R = TPR \\ P = \frac{TP}{TP + FP} \\ F = \frac{2PR}{P + R} \\ A = \frac{TP + TN}{TP + TN + FP + FN} \end{cases} \quad (8)$$

式中,TPR项表示真正类率,代表本身为异常数据点、检验为异常数据点的检测结果与真正异常数据点的比率;FPR项表示假正类率,代表本身为正常数据点、检验为异常数据点的检测结果与真正正常数据点的比率;R项表示召回率;P项表示精确率,代表预测是异常实际也是异常的样本数;F项是P和R的加权调和平均,常用的是F1值(P和R的权值各取0.5);A项表示正确率。六项异常检测评价指标中,假正类率FPR为逆向指标,其余指标均为正向指标。

### 1.3 电力变压器噪声采集

本文电力变压器噪声数据是通过课题组自主研发的电力变压器噪声采集装置测量所得,该装置采用的声压级传感器精度为I级,采样频率为48 kHz,测量噪声频段从20 Hz-20 000 Hz,如图1所示,为某500 kV变电站现场采集500 kV变电站噪声信号。



图1 某500 kV变电站主变噪声采集现场




图2 某500 kV变电站中主变噪声信号

现场采集的噪声典型数据检测一段500 kV变电站

主变压器噪声采样的噪声时序数据如图2所示,共计4 800个采样点。

## 2 算例分析

### 2.1 方法流程

将S-H-ESD方法应用于电力变压器噪声信号分析,其分析流程如图3所示,首先通过STL分解将原始时序数据分解为长趋势、周期和残差分量,再采用ESD算法检验残差分量,将偏离中位数超出阈值的数据点作为变压器噪声信号的异常点,从而完成原始噪声信号的异常点定位。具体而言,针对一维时序变压器噪声信号数据,首先通过STL分解方法处理原始噪声电压数据,将长趋势、周期分量和残余分量从原始时序数据中单独分离出来,噪声信号的异常波动会被留在残差分量中,这里仅对残余分量进行分析;其次通过S-H-ESD方法检验存在的数据点异常,通过计算当前整个序列的中位数、绝对中位数得到最大检验统计量 $R_j$ ,将其与临界阈值 $\lambda_j$ 进行比较,界定超出阈值的数据为异常数据点;再移除异常点,得到新序列,对新序列重复上面的检验步骤;最后当满足不存在最大检验统计量超出阈值的数据点迭代停止条件时,停止检测并输出检测出的异常点,检测完成。

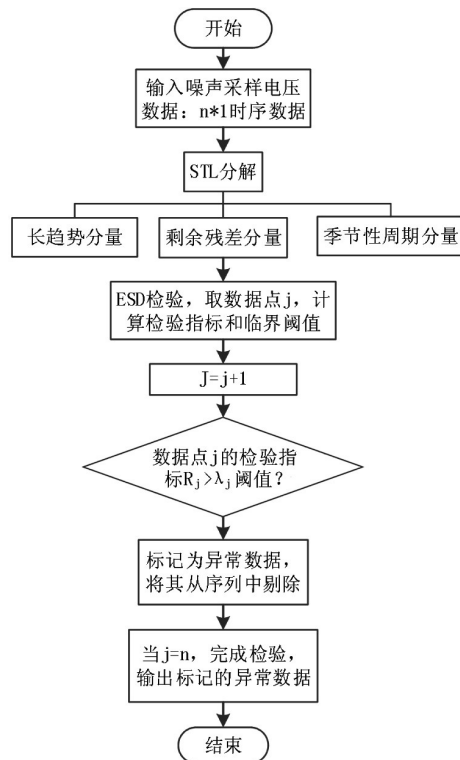


图3 噪声信号异常检测S-H-ESD算法流程图

### 2.2 算例分析

按照1.1节中S-H-ESD异常检测算法流程,对图2中某500 kV变电站主变噪声信号时序数据进行分析,将原始噪声信号波形数据导入python中,分别采用传统时间

序列分解方法和STL分解法将原始时序数据分解为趋势分量、周期分量和残差分量,分解结果分别如图4至图6所示。




图4 趋势分量示意图

图4表示的是原始时序数据中具有长期趋势特性分量,图5表示的是原始时序数据中反复出现的周期分量,图6表示的是原始时序数据去除长期趋势分量和周期分量后的残差分量。其中,使用蓝色线表示标注的趋势、周期和残差分量是采用传统时间序列分解方法得到的,使用红色线表示标注的趋势、周期和残差分量是采用STL分解得到的。




图5 周期分量示意图




图6 残差分量示意图

与原始噪声信号对比可以发现,采用传统时间序列分解方法,异常点特征在周期分量和残差分量中都有特征,且在残差分量中异常点特征与原始噪声信号中的特征趋势不一致,在STL分解结果中,异常点的特征被完整保留在残差分量中,因此,仅通过检测残差分量中存在的异常特征即可定位原始噪声信号中存在的异常点。

将图6残差分量时间序列数据记为待检验序列,采用S-H-ESD方法对其进行异常点检测,利用式(5)计算待

检验序列的中位数与绝对中位数来表示最大检验统计量,当最大检验统计量大于对应的临界阈值时,判定数据为异常数据点,将异常点数据记录在异常数据集中,并将其从检验序列中移除形成新的待检验序列,重复进行检验步骤,直至无新的异常点,停止迭代,输出检验结果分别如图7所示。基于1.2节中目标检测评价指标对检测结果进行评价,如表2所示。




图7 残差分量中检测异常点示意图

表2 S-H-ESD检测结果表

	实际正例	实际负例	检测合计
检测正例P	TP=17	FP=10	27
检测负例N	FN=16	TN=4 757	4 773
实际合计	33	4 767	4 800

根据表2可知,检测序列总量为4 800个数据,其中异常点实际为33个点,正常点实际为4 767个点;S-H-ESD检测结果中,TP项为17,FP项为10,FN项为16,TN项为4 757,检测出的异常点为27个,其中真异常点为17个,检测出的正常点为4 773个,其中假正常点为16个。为进一步对上述评估结果进行评价,按照式(8)计算对表2进行计算,进一步得到的评价检测结果的衍生指标值,结果如表3中所示。

表3 S-H-ESD检测结果评价指标

TPR	FPR	R	P	F	A
0.515 2	0.002 1	0.515 2	0.629 6	0.566 7	0.996 7

在表3中,TPR项表明异常点检测结果的真正类率为51.52%,是将异常数据点正确检测的数量占据异常数据点总量的比率;R项表明异常点检测结果的召回率为51.52%,在数值上等同于TPR;P项表明异常点检测结果的精确率为62.96%,是正确检测的异常点占据异常点检出总量的比率;F项是P和R的加权调和值,为56.67%;A项表明异常点检测结果的正确率为99.67%,表明检测异常点和检测正常点与数据实际类别的正确匹配程度,取值越大表明检测效果越理想;FPR项表明异常点检测结果的假正类率为0.21%,是将正常数据点归为异常数据点的检测结果占据正常数据点总量的比率,取值越小表明检测效果越理想,因此,上述指标均说明本方法对电力变压器噪声信号异常点检测具有较好的检测效果。

### 2.3 方法对比

为进一步验证本文的准确性,将本文方法与当前常用的Prophet模型方法<sup>[11-12]</sup>进行对比分析,Prophet模型方法在预测值上界、下界的基础上分别加上和减去3-sigma范围作为数据波动的合理区间,将超出范围标记为异常点。将本文方法与Prophet模型方法的检测结果进行对比分析,检测结果评价对比如表4中所示。

表4 采用两种方法的异常检测结果评价指标对比

方法	TPR	FPR	R	P	F	A
S-H-ESD	0.515 2	0.002 1	0.515 2	0.629 6	0.566 7	0.996 7
Prophet	0.424 2	0.173 3	0.424 2	0.016 7	0.032 1	0.824 0

由表4可知,S-H-ESD方法的检测效果评价指标,TPR为51.52%,FPR为0.21%,R项为51.52%,P项为62.96%,F项为56.67%,A项为99.67%;采用Prophet模型方法的检测效果评价指标,TPR为42.42%,FPR为17.33%,R项为42.42%,P项为1.67%,F项为3.21%,A项为82.40%。对比评价指标可以发现:S-H-ESD方法的TPR、R、P、F、A等5项正向评价指标均高于采用Prophet模型方法;S-H-ESD方法的逆向评价指标FPR低于采用Prophet模型方法。因此,S-H-ESD方法用于检测异常数据点具有更好效果。

### 3 结束语

现实场景中对变压器噪声监测采样电压数据的异常点检测问题,通常需要在小样本情况下进行高效检测,而传统的方法在小样本情形下检测正确率有待提高,制约检测效率,本文提出基于S-H-ESD的电力变压器噪声信号分析方法,实现原始噪声信号数据中的异常点定位,对小样本情形下异常点检测正确率达到99.67%,本文提出的S-H-ESD(Seasonal-Hybrid-ESD)算法在国家自然科学基金项目中主要是提供了一种轨道扣件类复杂曲面仿形加工点云数据去噪光顺算法,去噪光顺算法利用S-H-ESD(Seasonal-Hybrid-ESD)算法将点云数据分解,以进行噪声点的识别与光顺,然后利用改进后的双边滤波算法对点云数据进行整体光顺。

#### 参考文献:

[1] JB/T 10088-2004.6 kV~500 kV级电力变压器声级[S]. 2004.

[2] 赵文清,祝玲玉,高树国,等.基于多源信息融合的电力变压器故障诊断方法研究[J].电力信息与通信技术,2018,16(10):25-30.

[3] 刘凤魁,邓春宇,王晓蓉,等.基于改进快速密度峰值聚类算法的电力大数据异常值检测[J].电力信息与通信技术,2017,15(6):36-41.

[4] 代杰杰,滕莹冰,龚越明.基于区间集聚类分析的电力设备状态异常检测方法[J].电力信息与通信技术,2019,17(11):1-6.

[5] 钟志琛.基于网络流量异常检测的电网工控系统安全监测技术[J].电力信息与通信技术,2017,15(1):98-102.

[6] 吴晓天,周年光,彭继文,等.电力变压器噪声特性与相关因素分析[J].电力科学与技术学报,2018,33(3):81-85,146.

[7] 舒畅,金潇,李自品,等.基于CEEMDAN的配电变压器放电故障噪声诊断方法[J].高电压技术,2018,44(8):2603-2611.

[8] 周兵,裴春明,倪园,等.特高压交流变电站噪声测量与分析[J].高电压技术,2013,39(6):1447-1453.

[9] Gupta M,Gao J,Aggarwal C C,et al.Outlier Detection for Temporal Data:A Survey[J].IEEE Transactions on Knowledge&Data Engineering,2014,26(9):2250-2267.

[10] Zimek A,Schubert E,Kriegel H P.A survey on unsupervised outlier detection in high-dimensional numerical data[J].Statal Analysis&Data Mining,2012,5(5):363-387.

[11] Taylor S J,Letham B.Forecasting at scale[J].The American Statistician,2018,72(1):37-45.

[12] 葛娜,孙连英,石晓达,等.Prophet-LSTM组合模型的销售量预测研究[J].计算机科学,2019,46(S1):446-451.

[13] Aggarwal C C.An introduction to outlier analysis[M]//Outlier analysis.Springer,Cham,2017:1-34.

[14] Micenkov á B,McWilliams B,Assent I.Learning representations for outlier detection on a budget[J].IEICE Transactions on Fundamentals of Electronics,Communications and Computer Sciences,2015,1(1):1-18.

[15] Zhao Y,Hryniewicki M K.XGBOD:Improving Supervised Outlier Detection with Unsupervised Representation Learning[C]//Proceedings of the 2018 International Joint Conference on Neural Networks(IJCNN),2019:723-731.DOI:10.1109/IJCNN.2018.8489605.

[16] V.Chandola,A.Banerjee,and V.Kumar,Anomaly Detection:A Survey[J].ACM Computing Surveys,2009,41(3):1-58.

[17] Aggarwal,Charu C.Outlier Ensembles[J].Acm Sigkdd Explorations Newsletter,2017,14(2):49-59.

[18] Zimek A,Campello R,Sander J.Ensembles for unsupervised outlier detection:challenges and research questions a position paper[J].Acm Sigkdd Explorations Newsletter,2014,15(1):11-22.

[19] Aggarwal C C,Sathe S.Outlier ensembles:An introduction[M].springer publishing company,West-Berlin and Heidelberg,2017.

[20] 左志宏,赵云鹏,刘竹,等.基于时间序列分解与支持向量回归的短期电力能耗预测研究[J].信息系统工程,2019(8):95-97.

[21] Robert C,William C,Irma T.STL:A seasonal-trend decomposition procedure based on loess[J].Journal of official statistics,1990,6(1):3-73.

[22] Hochenbaum J,Vallis O S,Kejariwal A.Automatic anomaly detection in the cloud via statistical learning[J].Computer Science,2017,1(1):1-13.

[23] Cleveland W S.Robust locally weighted regression and smoothing scatterplots[J].Journal of the American statistical association,1979,74(368):829-836.

作者简介:罗浪(1975-),男,大专,工程师/高级技师,研究方向:变电设备高压试验以及带电检测。