

基于季节分解和LSTM的配电网故障预测

蔡礼¹, 邓芳明², 曾晗², 曾兵³, 李唐兵⁴, 鲍超斌⁵

(1. 国网江西省电力有限公司电力科学研究院, 江西 南昌 330096; 2. 华东交通大学, 江西 南昌 330013; 3. 江西水利电力大学, 江西 南昌 330099; 4. 南昌科晨电力试验研究有限公司, 江西 南昌 330096; 5. 武汉启亦电气有限公司, 湖北 武汉 430205)

摘要:针对配电网故障预测精度低导致的配网运行不稳定问题,提出一种基于STL-LSTM的配电网故障预测模型。首先对配电网故障数据集进行数据分析,使用STL(seasonal and trend decomposition using loess, STL)进行时间序列分解,然后引入长短时记忆网络(long-short memory network, LSTM),对数据进行特征提取,对处理后的数据进行预测。选择平均绝对百分比误差(MAPE)与决定系数(R^2)作为性能评价指标。实验结果表明,该模型的MAPE和 R^2 分别达到0.06和0.78,相较于其他模型具有更优秀的性能,为配电网故障数据预测提供了一种精度可靠的预测方法。

关键词:季节分解;LSTM;特征提取;配电网故障预测;MAPE; R^2

中图分类号:TP 206 **文献标志码:**B **文章编号:**1006-348X(2025)04-0001-05

0 引言

随着科技水平的迅速发展和越来越多的能源被开发利用,配电网承载着越来越多的能源配送任务,同时也面临着巨大的挑战。配电网系统作为电力系统的“血液”运输系统,其部署面积最为广泛,更容易受到各种因素影响从而产生故障^[1]。作为整个系统的尾端环节,若不能及时准确定位、隔离并自愈,将会对电网系统的安全稳定运行产生极大影响^[2]。因此,对于配电网的故障精确预测,可以使相应的处理措施能及时跟进^[3]。

近年来,国内外对数据预测进行了大量研究,数据预测常采用物理方法和统计方法^[4]。传统配电网故障预测采用物理方法预测,物理方法作为一种传统方法着重于构建配电网故障之间关系的数学模型,研究配电网故障发生诱因,与其高相关性的部件产生的一系列故障^[5]。物理方法预测精度高,但步骤较多、过程复杂、参数求解困难,不适合实际应用^[6]。统计方法通过分析历史配电网故障数据,对配电网故障数量进行预测,相较于物理方法,统计方法的可靠性和实用性更强^[7-8]。

在此类预测工程中,机器学习技术的性能较为优

秀,可以做出精确的预测。文献[9-10]提出了数据驱动方法,数据驱动不需要系统的公式,模型简单,容易应用到实际应用,但是数据驱动会盲目选择目标,从而求解错误的目标;文献[11-12]提出了神经网络方法,但预测精度不能满足工程需要,由于学习算法较弱,存在过拟合特征,容易陷入局部最优解;针对神经网络存在的缺点,SVM采用结构最小化原则,因此具有强大的泛化能力,能够较好地解决各类神经网络中存在的局部最小值问题^[13-14],具有优秀的鲁棒性,然而,SVM选取参数较为困难,选取不同的参数,分类的效果差别非常大;文献[15-16]提出了一种LSTM方法,LSTM网络具有强大的记忆时序信息能力,解决了长序列训练过程中存在的梯度消失和梯度爆炸的问题,但在处理并行任务时,精度不高,无法满足预测需求。

与一般的时间序列数据不同,配电网故障数据具有更多的随机噪声和多种因素间的相互影响^[17-18],数据的趋势和规律难以准确描述^[19-20]。文中提出一种基于STL-LSTM的配电网故障预测模型,首先对配电网故障数据集进行数据筛选、整理,利用STL对数据进行时间序列分解,提取数据特征并去除噪声,最后通过LSTM预测模型对结果进行预测,以平均绝对百分比误差(MAPE)与决定系数(R^2)作为精度标准,

收稿日期:2025-04-07

基金项目:国家自然科学基金面上项目(52277148);国家自然科学基金面上项目(52377103)。

作者简介:蔡礼(1983),男,博士,高级工程师,从事电力设备无损检测技术研究。

对预测模型进行评估。

1 预测模型方案

1.1 方案设计

图1为文中提出的配电网故障预测模型结构。该模型由使用的数据、预处理方法和深度学习模型训练(LSTM)组成。模型结合故障编号、故障日期和故障类型等数据,采用STL预处理方法去除序列数据的趋势和季节性,利用LSTM算法对配电网故障进行预测。

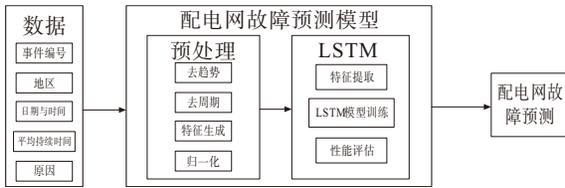


图1 预测模型结构

1.2 STL与LSTM的融合

融合STL-LSTM网络,将配电网故障数据分解为趋势分量、季节分量和剩余分量到一个LSTM结构中进行故障数据预测。

STL方法分为内循环和外循环。内循环主要计算趋势分量和季节分量,外循环主要用于调节外环的鲁棒性权值。

经过时间序列分解后,对原始数据中的随机噪声进行滤波处理,得出原始数据过滤的趋势项和季节项。在配电网故障数据趋势更清晰的基础上,加入季节分量和残差作为原始数据的特征,可以提高LSTM的预测精度和系数。

1.2.1 外循环

外循环主要用于调整鲁棒性权值。如果数据序列中有一个离群值,那么余数会偏大。

$$h=6 \times \text{median}(|R_v|) \quad (1)$$

对于位置为v的数据点,其鲁棒性权重为:

$$\rho_v=B(R_v|h) \quad (2)$$

其中B函数为二方函数:

$$B(u)=\begin{cases} (1-u^2)^2 & \text{for } 0 \leq u < 1 \\ 0 & \text{for } u > 1 \end{cases} \quad (3)$$

1.2.2 内循环

内循环主要计算趋势分量和季节分量。其中 $n_{(s)}$ 、 $n_{(1)}$ 、 $n_{(t)}$ 为LOESS平滑参数, $n_{(p)}$ 是一个季节的样

本。赋初值,令 $T_v^{(0)}=0$ 。

下列步骤为STL的内循环过程:

1) 步骤1:去趋势, $Y_v-T_v^k$;

2) 步骤2:周期子序列平滑,选用LOESS($q=n_{(s)}$, $d=1$)对每个子序列进行回归,向前后各延伸一个循环,组合得到长度为 $(N+2 \times n_p)$ 的时间序列 $C_v^{(k+1)}$, $V=-n_{(p)}+1, \dots, -N+n_{(p)}$;

3) 步骤3:周期子序列低通滤波,对 $C_v^{(k+1)}$ 进行依次平均,选用LOESS($q=n_{(t)}$, $d=1$)对每个子序列进行回归,得到子序列 $L_v^{(k+1)}$, $V=1, \dots, N$;

4) 步骤4:去除平滑周期子序列趋势, $S_v^{(k+1)}=C_v^{(k+1)}-L_v^{(k+1)}$;

5) 步骤5:去周期, $Y_v-S_v^{(k+1)}$;

6) 步骤6:趋势平滑,对 $Y_v-S_v^{(k+1)}$ 进行局部加权回归,得到 $T_v^{(k+1)}$,需要选定平滑参数 $n_{(1)}$;

上述步骤迭代至收敛,得:

$$S_v=S_v^{(k+1)} \quad (4)$$

$$T_v=T_v^{(k+1)} \quad (5)$$

$$R_v=Y_v-S_v-T_v \quad (6)$$

1.2.3 LSTM层

图2显示了LSTM单元的体系结构,LSTM单元由三个门组成:遗忘门、输入门和输出门。

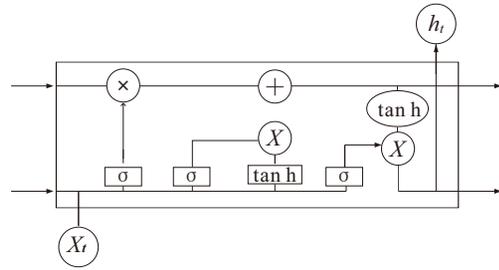


图2 LSTM架构

遗忘门决定了信息的存储或舍弃, f_t 代表遗忘门的输出,公式如下:

$$f_t=\sigma(W_f[h_{t-1},X_t]+b_f) \quad (7)$$

式中: σ 代表sigmoid激活函数; W_f 代表权重; h_{t-1} 代表上一时刻LSTM的输出值; X_t 当前时刻的输入值; b_f 代表偏置项。

输入门用来存储需要记忆的信息。公式如下:

$$i_t=\sigma(W_i[h_{t-1},X_t]+b_i) \quad (8)$$

$$\tilde{c}_t=\tan h(W_c[h_{t-1},X_t]+b_c) \quad (9)$$

$$C_t=f_t \times C_{t-1}+i_t \times \tilde{c}_t \quad (10)$$

式中： i_t 是输入门的sigmoid激活函数； \tilde{c}_t 为本级信息； C_t 为新的单元； C_{t-1} 为上一级单元。

输出门决定了输出信息，其公式如下：

$$o_t = \sigma(W_o[h_{t-1}, X_t] + b_o) \quad (11)$$

$$h_t = o_t \times \tan h(C_t) \quad (12)$$

式中： o_t 代表输出层的sigmoid激活函数； h_t 代表LSTM的输出单元。

对STL时间分量进行分解，得到趋势分量、季节分量和残差。STL可以在原始数据的基础上消除随机噪声，因此将趋势分量、季节分量和剩余分量与原始数据结合，作为LSTM神经网络的输入。

输入层和前两个隐藏层是LSTM层。LSTM神经网络的输入是对数据进行分解后得到的趋势分量和季节分量，首先选取LSTM神经网络输入层中的16个神经元，第2层96个神经元，第3层172个神经元。

理论上，增加隐层数量或隐藏层中的神经元数量，可以提高LSTM神经网络的空间表达能力。虽然通过STL对交通数据进行分解，排除了数据的噪声，但模型的复杂性也可能导致过拟合。Dropout可以有效缓解过拟合的发生，并在一定程度上实现正则化效果。为了防止过拟合，将模型中的dropout rate设为0.3。

1.2.4 全连接层

最后一层为负责将LSTM提取的特征映射到预测输出的模型末端的全连接层，每个节点都与上一层的所有节点相连，利用上一层节点来合成之前提取的特征。在全连接层的第一层中设置50个神经元，第二层中设置1个神经元作为模型的输出。为了提高收敛速度，在第一全连通层使用ReLU作为式(13)的激活函数，为输出层选择sigmoid函数。

$$f(z) = \begin{cases} z, z \geq 0 \\ 0, z < 0 \end{cases} \quad (13)$$

2 数据的准备与分析

数据来源。文中以特定区域配电网运行信息为基础分析对象，原始资料由当地供电企业提供，主要包括配电系统异常事件档案及监测装置采集的实时参数。样本库整合了近36个月的系统故障案例，涉及500起典型事故，详细记载了每起事件的时序特

征、地理坐标、异常类别、影响时长及处置方案等核心要素；同时，系统还接入了部署于关键配电节点的传感设备所捕获的动态监测信息，这些辅助数据包含超过200万条关于电流强度、电压水平、频率波动等关键性能指标的实时记录。

2.1 数据准备

数据特征筛选与处理流程。在开展数据分析工作前，必须对原始数据进行特征筛选与处理。配电网运行状态受多维度参数共同影响，其中电流强度、电压水平及系统频率等核心参数是分析故障的关键变量；电流作为电力系统最敏感的故障指示器，在故障状态下往往呈现剧烈波动；电压参数能够直观反映配电网负载状况，偏离正常范围的电压值均可能诱发系统故障；频率参数则是评估电网稳定性的核心指标，频率异常通常预示着负荷失衡或设备异常。同时，环境温度、空气湿度以及负荷波动等参数同样构成潜在的故障诱因，因此科学筛选和提取这些特征参数对实现配电网故障精准预测具有决定性作用。

配电网原始数据预处理环节。在电力系统运行监测过程中，获取的配电网信息往往包含多种数据质量问题，包括但不限于离群点、干扰信号以及不完整记录等，这些缺陷将显著降低后续建模分析与算法应用的可靠性，必须实施专业化的净化与滤波操作。具体而言，测量数据中的异常点可能源自检测装置异常、录入失误或环境扰动，其典型特征为数值分布明显超出合理区间边界。

2.2 数据分析

配电网故障预测的结果主要通过预测的准确性和预测趋势的拟合来衡量，因此需要选择有影响的特征来保证预测的效果。然而，配电网数据集的许多特征对故障预测没有显著影响。根据以上分析，表1中列出配电网故障的属性。

表1 配电网故障属性

属性	含义
事件编号	故障编号
地区	故障发生的地区
日期及时间	故障发生日期及时间
平均持续时间	因故障导致的用户停机时长
原因	故障原因

虽然配电网故障数据中包含了相关的数据集，但不能将当天的数据作为特征引入回归预测算法中。因此，在配电网的故障数据数据中，只能得到随时间

变化的数据值,这就造成了时间序列问题。时间序列(也称为动态序列)是指同一统计指标的值按时间顺序排列的序列,其分析的主要目的是根据现有的历史数据预测未来。

根据配电网故障数据集的特点,将配电网故障预测建模为时间序列预测问题。

3 实验结果与分析

对 STL-LSTM 模型的预测结果进行分析,并通过引入 STL 时间序列分解来分析 LSTM 模型拟合度和预测能力的提高。此外,为了验证 STL-LSTM 网络的优点。还选择了经典的时间序列预测 ARIMA 模型、LSTM 模型和随机森林进行比较。

3.1 评价指标

为了全面准确地分析 STL-LSTM 模型的预测结果,引入了两个评价指标来分析预测结果。包括平均绝对百分比误差(MAPE)和决定系数 R^2 。下面将介绍这些评价指标的定义。

平均绝对百分比误差(MAPE),也称为平均绝对百分比偏差(MAPD),是统计中对预测方法的预测精度的度量。例如趋势估计,它通常用百分数来表示精度,由以下公式定义:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{y_i} \quad (14)$$

式中: y_i 为真实值; \hat{y}_i 为预测值; n 为测试集的数据数量。

在回归中,决定系数 R^2 是回归预测如何接近真实数据点的统计度量。当模型拟合效果不好时, R^2 的值可能会超出0到1的范围。 R^2 的值越接近于1,表明回归预测越符合数据。

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (15)$$

3.2 实验结果分析

实验使用的是配电网故障数据集。图3所示的数据直观地判断为随机序列。为了提高配电网故障预测的准确性,文中引入了STL,将原始数据分解为趋势分量、季节分量、残差。如图3所示。

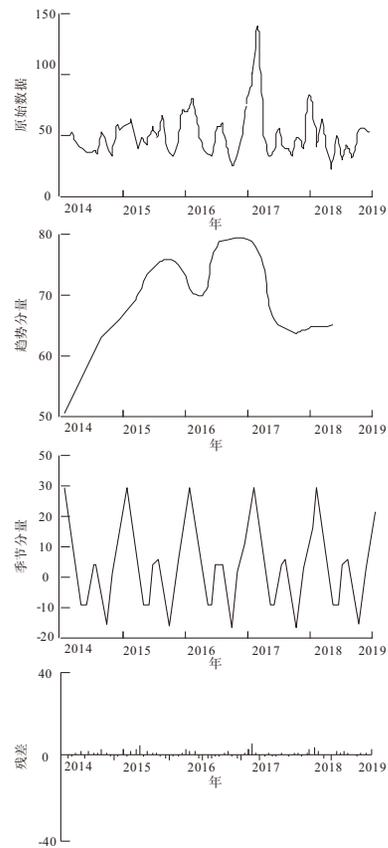


图3 时间序列分解图

由于STL对离群值具有鲁棒性,对离群值进行加权,使得在对所有样本的趋势进行分析时,将意外影响因素最小化,对数据集的分析更加可靠。在趋势分量图中,与原始数据相比,STL的趋势分量更加平滑,消除意外因素引起的干扰。从季节分量图中可以清楚地看出,原始数据是一段固定的时间,显示出季节性的特征。趋势的分解可以很好地表明原始数据不是随机序列,而是具有一定的周期性。残差图作为异常点的集合,有曲线振荡没有规律,这些点对原始数据产生严重干扰,使用STL后,趋势和季节的鲁棒性不会被数据中的异常噪声干扰。

以 STL-LSTM 的 MAPE 和 R^2 评价指标对经典的时间序列预测 ARIMA 模型、LSTM 算法和随机森林进行了比较。在实验过程中,通过尝试不同的算法学习速率对配电网故障进行预测。为了使模型更有效,在模型中设置学习率为0.2。

LSTM 算法克服消失的梯度下降,避免长期依赖性问题,能够充分处理特征,提高预测的性能。同时,引入了 STL 时间序列分解,可以看到精度和泛化能力得到了进一步的提高。如图4所示,STL 的拟合效果最好。如表2所示,以 MAPE 和 R^2 两个评价指标为

标准,对各算法进行比较,STL-LSTM性能最好。

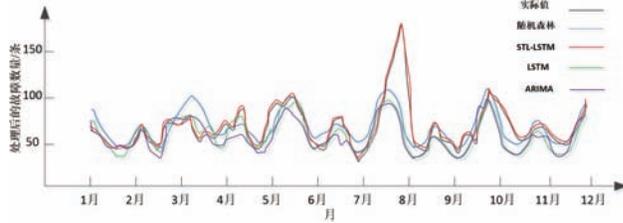


图4 各模型拟合程度

表2 各算法的MAPE与 R^2 值

	ARIMA	LSTM	随机森林	STL-LSTM
MAPE	0.26	0.14	0.19	0.06
R^2	0.59	0.73	0.65	0.78

4 结语

文中引入基于STL-LSTM模型对配电网故障数据进行预测。在分析故障数据特点的基础上,建立了STL-LSTM配电网故障预测模型。为了评价模型的性能,将模型与经典的时间序列预测ARIMA模型、LSTM模型和随机森林算法进行比较。仿真结果表明,该模型的MAPE和 R^2 分别达到0.06和0.78,相较于其他模型具有更优秀的性能,为配电网故障数预测提供了一种新方法。

参考文献:

- [1] 郝丽丽,王辉,王国栋,等.含分布式电源配电网运行风险的影响因素溯源[J].电力自动化设备,2021,41(01):27-37.
- [2] 高锋阳,李昭君,袁成,等.含特殊负荷的配电网故障定位与识别[J].电力自动化设备,2020,40(08):96-108.
- [3] 张健磊,高湛军,陈明,等.考虑复故障的有源配电网故障定位方法[J].电工技术学报,2021,36(11):2265-2276.
- [4] Ognjanovic I, Gasevic D, Dawson S. Using institutional data to predict student course selections in higher education[J]. The Internet and Higher Education, 2016, 29: 49-62.
- [5] Khameneh P A, Lavasani S M M, Nodehi R N, et al. Water distribution network failure analysis under uncertainty[J]. International Journal of Environmental Science and Technology, 2020, 17(04): 421-432.
- [6] Fan C, Xiao F, Zhao Y. A short-term building cooling load prediction method using deep learning algorithms[J]. Applied energy, 2017, 195: 222-233.
- [7] Chen C H. An arrival time prediction method for bus system [J]. IEEE Internet of Things Journal, 2018, 5(05): 4231-4232.
- [8] Ren L, Meng Z, Wang X, et al. A Wide-Deep-Sequence Model-Based Quality Prediction Method in Industrial Process Analysis[J]. IEEE Transactions on Neural Networks and Learning Systems, 2020, 31(09): 3721-3731.
- [9] Feng C, Cui M, Hodge B M, et al. A data-driven multi-model methodology with deep feature selection for short-term wind forecasting[J]. Applied Energy, 2017, 190: 1245-1257.
- [10] Wang H Q, Cai Y N, Fu G Y, et al. Data-driven fault prediction and anomaly measurement for complex systems using support vector probability density estimation[J]. Engineering Applications of Artificial Intelligence, 2018, 67: 1-13.
- [11] Abiodun O I, Jantan A, Omolara A E, et al. State-of-the-art in artificial neural network applications: A survey[J]. Heliyon, 2018, 4(11): e00938.
- [12] Goldberg Y. Neural network methods for natural language processing[J]. Synthesis Lectures on Human Language Technologies, 2017, 10(01): 1-309.
- [13] Du J, Liu Y, Yu Y, et al. A prediction of precipitation data based on support vector machine and particle swarm optimization (PSO-SVM) algorithms[J]. Algorithms, 2017, 10(02): 57.
- [14] Zhang P Y, Shu S, Zhou M C. An online fault detection model and strategies based on SVM-grid in clouds[J]. IEEE/CAA Journal of Automatica Sinica, 2018, 5(02): 445-456.
- [15] Shahid F, Zameer A, Muneeb M. Predictions for COVID-19 with deep learning models of LSTM, GRU and Bi-LSTM [J]. Chaos, Solitons & Fractals, 2020, 140: 110212.
- [16] Zhang S, Wang Y, Liu M, et al. Data-based line trip fault prediction in power systems using LSTM networks and SVM [J]. IEEE Access, 2017, 6: 7675-7686.
- [17] Qin X, Wang P, Liu Y, et al. Research on distribution network fault recognition method based on time-frequency characteristics of fault waveforms[J]. IEEE Access, 2017, 6: 7291-7300.
- [18] Mahdavejad M S, Rezvan M, Barekatin M, et al. Machine learning for Internet of Things data analysis: A survey[J]. Digital Communications and Networks, 2018, 4(03): 161-175.
- [19] Chen D, Zhang J, Jiang S. Forecasting the Short-Term Metro Ridership With Seasonal and Trend Decomposition Using Loess and LSTM Neural Networks[J]. IEEE Access, 2020, 8: 91181-91187.
- [20] Wen Q, Gao J, Song X, et al. RobustSTL: A robust seasonal-trend decomposition algorithm for long time series[J]. Proceedings of the AAAI Conference on Artificial Intelligence. 2019, 33: 5409-5416.