

基于灰色关联和麻雀搜索算法的阶段性线损自适应快速预测方法

陈俏玲[†], 徐美霞

(广东电网有限责任公司阳江供电局, 广东 阳江 529500)

摘 要:由于输电线路内外环境特征冗余,若忽略了外环境特征对线损的影响,难以获取影响因子间的关联度,导致线损预测结果偏差较大。因此,提出了基于灰色关联和麻雀搜索算法的阶段性线损自适应快速预测方法。构建内环境以及外环境两种线损影响因子,采用灰色关联分析方法,通过计算数据列形态的灰色关联系数,得到每个影响因子的关联度,聚类解析阶段性的线损特征,引入麻雀搜索算法,实现自适应的快速线损预测。实验结果表明:所提方法应用后,线损电量与实际结果高度一致,预测结果准确度较高,满足了资源优化配置的现实需求。

关键词:线损预测;灰色关联;麻雀搜索算法;阶段性预测;自适应快速预测;预测方法

中图分类号:TM73

文献标识码:A

A Stage Adaptive Fast Prediction Method for Line Loss Based on Grey Correlation and Sparrow Search Algorithm

CHEN Qiaoling[†], XU Meixia

(Yangjiang Power Supply Bureau of Guangdong Power Grid Co., Ltd., Yangjiang, Guangdong 529500, China)

Abstract: Due to the redundancy of internal and external environmental characteristics of transmission lines, if the influence of external environmental characteristics on line losses is ignored, it is difficult to obtain the correlation between influencing factors, resulting in significant deviation in line loss prediction results. Therefore, a phased adaptive fast prediction method for line loss based on grey correlation and sparrow search algorithm is proposed. Construct two types of line loss influencing factors, internal and external, using grey correlation analysis method. By calculating the grey correlation coefficient of the data column form, obtain the correlation degree of each influencing factor, cluster and analyze the phased line loss characteristics, and introduce sparrow search algorithm to achieve self adaptive and fast line loss prediction. The experimental results show that after the application of the proposed method, the line loss electricity is highly consistent with the actual results, and the accuracy of the predicted results is high, meeting the practical needs of resource optimization allocation.

Key words: line loss prediction; grey correlation; sparrow search algorithm; periodic prediction; adaptive fast prediction; prediction methods

在电力输送领域中,电能输送过程中存在着一定的损耗情况,这使得最终输送到电力设备中的

电能与预期值有着小幅度的偏差^[1]。为了使得电力输送的实际电能与目标所需的电能保持一致,对

这一过程中的线损进行预测,以此实现线损电能的补偿输送十分关键。对此,很多研究人员提出了线损预测方法。

文献[2]针对台区的线损预测方法进行研究。采用 stacking 集成学习模型分析当前的台区线路状态数据。计算数据均值,并以均值点为中心聚类相应数据。在此基础上结合决策树算法以及支持向量机技术,综合分析聚类数据特征,得出线损预测结果。但该方法仅考虑了线路数据均质特征,忽略了极点数据对预测结果的影响,导致线损数据分析存在较大的差值。文献[3]对海量低压台区的线损预测方法进行研究。基于采集的低压台区历史运行数据,分析影响线损状态的相关因子。通过皮尔逊相关系数的计算,提取相关因子的数据特征。将提取的特征作为神经元构建串级神经网络,结合梯度提升的过程,综合得出线损预测结果。但该方法仅考虑了历史运行数据下的线损状态,忽略了外界环境变化对线损预测的影响,导致得到的线损特征较为理想化。文献[4]针对低压配电网中的线损预测方法进行研究。基于季节性趋势下的线路状态数据,分析多个维度的线损特征,并通过矩阵转换的形式构建多维信息矩阵。在该矩阵中引入注意力机制,计算线损特征的权值系数,筛选出关键特征参数,综合得出线损预测结果。但该方法仅考虑了季节性变化的线损特征,忽略了季节因子影响线损状态滞后效应,导致矩阵数据信息存在较大的时间误差。文献[5]针对分布式发电的线损预测方法进行研究。分析该状态下的线路电力消耗特性,计算线路内外部的消耗差值。构建电力输送环境下的线路模型,代入相应的设备运行及停电状态数据,分析数据特征之间的相关性,从而得出线损预测结果。但该方法仅考虑了设备运行状态,忽略了线路的外环境状态,导致数据相关特征的拟合性较差。

考虑到上述文献所提出的线损预测方法无法满足当前电力系统等领域的设备元件运维需求,结合灰色关联和麻雀搜索算法,提出了一种阶段性线损自适应快速预测方法。该方法通过灰色关联的分析过程得到线损特征,结合麻雀搜索算法自适应影响变化,得到阶段性的线损预测值。

1 阶段性线损自适应快速预测方法设计

1.1 线损影响因子灰色关联分析

由于线损值受到多种因素影响,本研究采用灰

色关联的方法分析线损影响因子。灰色关联法是一种多因素分析方法,通过计算因素之间关联度的相似程度来评估它们之间的相互影响。这种方法在处理不完全信息或数据量较小的情况下表现优越,能够有效地揭示因素之间的内在关系。本研究将线损影响因子划分为内环境影响因子和外环境影响因子,如表 1 所示。

表 1 线损影响因子

类型	影响因子
内环境因子	变压器容量
	三相不平衡程度
	功率因数
	终端电能比
	负载率
	供电量半径
外环境因子	日均供电量
	负载形状系数
	日平均降水量
	日平均气温
	日平均湿度
	日平均风速
	用户数量

基于如表 1 所示的内、外环境因子,采用灰色关联分析两种类型影响因子的关联度。分别将影响因子相应的数据调整为数据列的形态,如式(1)和式(2)所示^[6]。

$$\hat{x} = \{x(a_1), x(a_2), \cdots, x(a_n)\} \tag{1}$$

$$\hat{y} = \{y(b_1), y(b_2), \cdots, y(b_m)\} \tag{2}$$

式中, $\hat{x}$ 和 $\hat{y}$ 分别表示内、外环境影响因子的数据序列, a_1 等表示内环境影响因子, $x(a_1)$ 表示相应的因子数据, b_1 等表示外环境影响因子, $y(b_1)$ 表示相应的因子数据, n 和 m 分别表示相应的影响因子分类,在本研究中分别取值 7 和 6。

在此基础上,计算影响因子数据列的灰色关联系数,如式(3)所示^[7-9]。

$$\begin{aligned} \epsilon(k) = & \frac{\min |x(a_1) - (a_2)| + \rho \max |x(a_1) - (a_2)|}{|x(a_1) - (a_2)| + \rho \max |x(a_1) - (a_2)|} \end{aligned} \tag{3}$$

式中, $\epsilon(k)$ 表示影响因子的关联系数, k 统一代指影响因子数据, ρ 表示分辨系数。

如式(3)所示,本文通过计算因子数据之间的最大差值与最小差值,分析得出内环境影响因子的

灰色关联系数,与之相似,外环境影响因子的灰色关联系数计算方法为替换相应的因子数据即可。

基于计算得到的灰色关联系数,分析线损影响因子的灰色关联度,如式(4)所示^[10]。

$$\gamma = \frac{1}{mm} \sum_{k=1}^n \epsilon(k) \quad (4)$$

式中, γ 表示灰色关联度。

通过上述步骤,完成基于灰色关联的线损影响因子分析过程。

1.2 阶段性线损特征解析

基于上述分析所得的线损影响因子灰色关联度,本研究通过分析不同时序数据下,不同影响因子的离群点阶段性特征,解析阶段性的线损特征。

构建影响因子数据空间,计算数据之间的欧式距离,如式(5)所示。

$$d_{ij} = \sqrt{(\tau_i - u_i(j))^2} \quad (5)$$

式中, i 和 j 分别表示空间内的两个随机数据, d_{ij} 表示两个数据之间的空间距离, τ_i 表示数据的时序特征, u_i 表示空间节点。

基于数据在空间中的欧式距离,聚类处理该数据。定义数据聚类簇点,如式(6)所示^[11]。

$$s(i) = \frac{\alpha(i) - \beta(i)}{\max(\beta(i), \alpha(i))^\tau} \quad (6)$$

式中, $s(i)$ 表示数据 i 的聚类簇点, $\alpha(i)$ 表示数据 i 与同一聚类簇的平均距离, $\beta(i)$ 表示数据 i 与其他聚类簇中心的距离。

在上述的数据聚类过程中,将极点数据作为聚类边缘,保留极点数据的线损特征^[12]。根据数据聚类的结果,以聚类簇以节点,分析线损影响因子数据的阶段性节点,如式(7)所示。

$$L(s) = \frac{\sum s(i) \in p \frac{l(o)}{l(p)}}{|Ns(i)|} \quad (7)$$

式中, $L(s)$ 表示聚类簇的离群点, o 表示聚类簇的关联度差值, p 表示正常点, $l(o)$ 和 $l(p)$ 分别表示相应的局部可达密度, N 表示聚类簇点数。

将上述计算得到的离群点作为线损特征的阶段性划分节点。根据每个划分节点之间的阶段性数据时序信息,解析相应的线损特征,如式(8)所示。

$$T(i) = \frac{1}{N - (mm - 1)} \sum_{i=1}^N L(s)(t_{\max} - t_{\min}) \quad (8)$$

式中, $T(i)$ 表示阶段性线损特征, $t_{\max}$ 和 $t_{\min}$ 分别表示阶段内的最大数据时序以及最小数据

时序。

通过上述步骤,完成阶段性的线损特征解析过程。

1.3 基于麻雀搜索算法的线损值自适应快速预测

根据解析得到的阶段性线损特征,分析得出线损预测值。为了加速这一分析进程,本研究引入麻雀搜索算法(Sparrow Search Algorithm, SSA)的最新变体自适应麻雀算法(Adaptive Sparrow Search Algorithm, ASSA)实现自适应的线损值快速预测。麻雀搜索算法是一种启发式优化算法,其灵感来源于自然界中麻雀的觅食行为。该算法通过模拟麻雀的飞行和觅食行为,寻找问题的最优解。自适应麻雀算法可以根据问题的特性和解的分布情况,自适应地调整麻雀搜索的参数和策略,例如,可以根据解的质量和分布情况动态调整种群大小、迭代次数、搜索步长等参数,以提高搜索效率和精度。在 ASSA 中,麻雀种群代表解空间中的候选解,食物资源则代表问题的目标函数值。通过不断更新麻雀的位置和食物资源,ASSA 能够逐渐逼近问题的最优解。

将解析得到的线损特征组作为麻雀搜索算法的初始种群,并变换为矩阵的形式,如式(9)所示。

$$\mathbf{A} = \begin{bmatrix} T_{11} & T_{12} & \cdots & T_{1\varphi} \\ T_{21} & T_{22} & \cdots & T_{2\varphi} \\ \vdots & \vdots & & \vdots \\ T_{\varphi 1} & T_{\varphi 2} & \cdots & T_{\varphi\varphi} \end{bmatrix} \quad (9)$$

式中, $\mathbf{A}$ 表示麻雀种群矩阵, φ 表示麻雀种群中的初始个体数量, φ 表示线损特征的空间维度。

基于初始的麻雀种群,代入变化的内、外环境影响因子数据,自适应更新麻雀种群的食物资源。分析在更新过程中,麻雀搜索的发现者的更新位置,如式(10)所示^[13,14]。

$$\mathbf{D}(q) = \mathbf{Q} \cdot \mathbf{A} + \exp\left(-\frac{T}{c \cdot \lambda_{\max}}\right) \quad (10)$$

式中, q 表示麻雀种群中的发现者, $\mathbf{D}(q)$ 表示发现者的更新位置, $\mathbf{Q}$ 表示更新的食物资源, c 表示随机数, $\lambda_{\max}$ 表示麻雀搜索算法的最大迭代次数。

在此基础上,设置麻雀种群中的预警者数量,并以随机的方法在种群中设置预警者个体。计算当前的种群整体适应度,如式(11)所示^[15]。

$$F = f(T) \exp \frac{\mathbf{D}_w - \mathbf{D}(q)}{r^2} \quad (11)$$

式中, F 表示麻雀种群整体适应度值, $f(T)$ 表示麻雀个体适应度值, $\mathbf{D}_w$ 表示当前麻雀种群中

的个体最劣位置, r 表示设置的预警者个体。
循环进行上述更新过程,直至满足算法的最大迭代次数,输出运算结果。

根据麻雀搜索算法,快速运算得到最优值。由此得出最终的线损预测结果,如公式(12)所示。

$$H = \sum_{T=1}^{\lambda} T_b \frac{(a^2 + b^2) P(t)}{U^2} \tag{12}$$

式中, H 表示线损预测值, T_b 表示麻雀搜索算法输出的最优值, $P(t)$ 表示当前时刻的有功功率, U 表示节点电压。

通过上述步骤,完成基于灰色关联和麻雀搜索算法的阶段性线损自适应快速预测方法的设计过程。

2 实 验

2.1 实验准备

采用本研究所提出的阶段性线损自适应快速预测方法进行线损预测实验,根据实验结果分析本研究所提方法的实践应用可行性。

本次实验采用某配电网架仿真线路的实际环境。以 20 min 为采样频率获取该配电网中的线路历史数据。经采集,共获取 6497 组线路历史数据。将该数据于计算机中实施数据清洗步骤,去除数据中的无关特征。

基于输电线路的实际应用情况,选用型号为 JL/G1A-240/40 的线路作为模拟样本,其主要参数配置如表 2 所示。

表 2 线路配置参数

项目	参数
外径/mm	21.66
直流电阻/(Ω/km)	0.1209
导线结构/mm	26/3.42-7/2.66
计算拉力/N	83370
内截面积/mm ²	4
导体结构/TS	56/0.30
额定电压/KVDC	30
耐温范围/°C	- 60 ~ + 200

以如表 2 所示参数的线路为依托,测试其线损情况。
将上述处理后的历史数据作为数据样本,模拟生成若干个线路负荷数据。根据每组数据中含有的负荷特征,为所选线路设置不同的线路运行环

境,并在线路的末端连接电力计量设备,用于获取实际输送的电量负荷数据,如图 1 所示。



图 1 线损数据测量电力计量设备

如图 1 所示,本次实验采用三相电相位测量仪作为线损数据的计量设备。该设备的频率量程为 15400 Hz,能够测定出较为精准的线损数据。

在上述环境的基础上,设置本次线损实验的外部环境。基于应用需求,在计算机中的 MATLAB 软件中模拟日平均温度、湿度等外环境状态数据,并根据历史数据中的相关特征,设置季节性趋势的电力输送环境,使得本次实验搭建的环境与实际线损环境保持一致。

设置麻雀搜索算法的初始参数,如表 3 所示。

表 3 麻雀搜索算法参数设置

参数项	参数设置
种群数量	50
迭代次数	200
发现者占比	20%
预警者占比	10%
安全值	0.8

基于上述所示参数实现本研究所提出的预测方法,并根据相应文献中的参数实现本次实验中的其他预测方法。

完成上述准备后,开展本次线损预测实验。

2.2 阶段性线损自适应快速预测

采用本研究所提方法进行线损预测实验,根据实验结果分析本研究所提方法的实践应用可行性。

随机选用一组模拟数据作为目标输送电能参数,并使用 MATLAB 调节这一过程中线路的外环境参数。经过实验,得到本研究所提方法的线损预测结果如图 2 所示。




图 2 灰色关联分析图像

由图 2 可知,在设置的环境参数下,应用本研究所提方法分析得出线损值的灰色关联度图像,得到关联系数为 0.9750 的结果。基于该结果,计算输出本研究所提方法的阶段性线损自适应快速预测结果,如表 4 所示。

表 4 阶段性线损自适应快速预测结果

阶段/℃	预测线损值/%	实际线损值/%
春秋阶段(10~20)	0.049561	0.0502
夏小阶段(20~30)	0.104623	0.1076
夏大阶段(30~50)	0.106456	0.1088
冬小阶段(-10~10)	0.095266	0.0972
冬大阶段(-50~-10)	0.096135	0.0984

由表 4 可知,本研究所提方法得出的线损预测结果根据外环境状态的季节性趋势呈现出了阶段性的自适应预测值。这一结果显示,在冬夏两季外环境温度有着较大幅度变化的情况下,线损预测值明显升高。这一预测结果与相应阶段的用电高峰期相吻合,符合电力系统的固有特性。对比可知,预测线损值与电力计量设备测定的实际线损值高度一致。从这一实验结果可以初步判断,本研究所提方法能够得出阶段性的自适应线损结果,具备实际应用可行性。

2.3 结果评价指标

为了更加直观地体现出本次线损预测实验结果的有效性,设置一个定量指标来评价本次实验中不同线损预测方法的实验结果。基于电力系统等领域及设备元件运维需求,本次实验采用线损电量来评价不同方法的入侵目标识别结果有效性。这一评价指标的计算方法如公式(13)所示。

$$E_p = \sum_l^{\lambda} I_x^2 R_l \tag{13}$$

式中, E_p 表示预测的线损电量值, λ 表示线路环境设置参数, l 表示实验轮次, I_x 表示预测的线路电流值, R_l 表示本次实验所选用线路的电阻值,取 0.1209 代入计算。

通过线损电量这一结果评价指标的计算,定量分析不同线损方法的实验结果,从而得出不同预测方法在线损预测实践中的应用有效性。

2.4 结果分析与讨论

为了保证本次实验结果的有效性,采用对比分析的方法对本次实验结果进行评价。分别采用文献[2]、文献[3]以及文献[4]所提出的线损预测方法作为本次实验的对比方法。基于上述设定的结果评价指标,分析并讨论不同方法的线损预测结果。

经过实验,得到不同线损预测方法的线损电量计算结果图像如图 3 所示。




图 3 不同方法线损预测结果

由图 3 可知,在本次线损预测实验中,随着实验外环境参数的调节变化,文献[3]和文献[4]所提方法得出的线损电量结果未呈现出阶段性变化的趋势,表明相应方法得出的线损预测结果未考虑到线路外环境对预测值的影响,预测结果较不准确。文献[2]所提方法以及本研究所提方法在外环境参数变化下,均呈现出了季节性趋势的阶段性线损电量结果,但与文献[2]所提方法相比,本研究所提方法计算得出的线损电量值与实际值更为接近,表明本文所提方法不仅受外力因素影响较小,并且得出的线损预测结果准确度较高。

为了更直观地比较不同方法的线损预测效果,对实验中不同方法的线损预测结果误差进行了对比分析,结果如表 5 所示。

如表 5 所示,从数据表中可以看出,本研究所提方法的平均误差最小,仅为 0.98%,表明其预测结果与实际线损电量值最为接近。最大误差为 2.15%,也远低于其他三种方法。同时,本研究所

提方法的误差范围也较小,这表明其预测结果具有较高的稳定性和可靠性。因此,在电力系统的线损预测工作中,本研究所提方法具有较高的实践应用价值。

表 5 不同方法线损预测误差结果

方法	平均误差/%	最大误差/%	最小误差/%
文献[2]方法	1.63	3.57	0.51
文献[3]方法	4.17	7.88	1.85
文献[4]方法	3.52	6.15	1.23
本文方法	0.98	2.15	0.21

3 结 论

电力输送领域中的线损预测对于实际的供电量有着较大的影响。为了满足供电服务需求,本研究提出了一种基于灰色关联和麻雀搜索算法的阶段性线损自适应快速预测方法,得出的线损预测结果呈现出了较高的准确度,快速得出阶段性的线损预测结果,不仅能够更好地适应电力系统的复杂性和不确定性,还能够有效减少预测的延迟。同时,考虑了季节性趋势的外环境影响,大幅度提高了线损预测结果的准确性性能,能够为相关配电工作提供更加精准的电量损耗数据,以便采取更加准确的电量供应措施,在此基础上,助力电力资源配置的优化,减少不必要的能源消耗,推动电力行业的经济性发展,有着较好的实践应用前景。

参考文献

[1] 王晨欣,夏嘉航,赵成勇,等. 降低直流线路损耗的并联电容换相换流器单位功率因数控制策略[J]. 电力系统自动化, 2022, 46 (5): 141—154.

[2] 李晋源,保富,胡凯,等. 基于 Stacking 集成模型的台区线损率预测方法研究[J]. 电测与仪表, 2023, 60 (1): 71—77.

[3] 霍成军,王玮茹,余昆,等. 基于小生境遗传算法优化串级神经网络的台区理论线损预测[J]. 科学技术与工程, 2021, 21 (23): 9897—9906.

[4] ZHANG Z L,YANG Y,ZHAO H,et al. Prediction method of line loss rate in low-voltage distribution network based on multi-dimensional information matrix and dimensional attention mechanism-long and short-term time-series network[J]. IET Generation, Transmission & Distribution, 2022, 16 (20):4187—4203.

[5] WANG Z B. A line loss management method based on improved random forest algorithm in distributed generation system[J]. Distributed Generation & Alternative Energy Journal,2022,37 (1):1—22.

[6] 王鹏,白玉岭,王林梅,等. 基于聚类划分与双向 LSTM 网络的台区线损率计算[J]. 电子器件, 2022, 45 (4): 964—969.

[7] 陈勤勤,陈华友,韩冰. 基于灰色关联度和 Shapley 值的区间组合预测模型及其应用[J]. 安徽大学学报(自然科学版), 2023, 47 (4): 16—24.

[8] 杨朗建,雷基林,宋国富,等. 农用柴油机活塞环组机油消耗和窜气的灰色关联分析与预测[J]. 农业工程学报, 2023, 39 (15): 57—66.

[9] 黄鑫康,刘萍,芦庆和,等. 基于改进麻雀搜索算法优化 SVR 和 FLAC3D 的开采地表沉降预测[J]. 矿业研究与开发, 2023, 43 (10): 110—118.

[10] 周梓轩,杨德岭,刘慧. 改进麻雀搜索算法在优化林分空间结构求解中的应用[J]. 东北林业大学学报, 2023, 51 (11): 68—73.

[11] 牛文政,曹付义,罗自赢,等. 四轮驱动电动汽车转向行驶自适应预测控制[J]. 现代制造工程, 2023, (7): 73—78.

[12] 郭万金,赵伍端,于苏扬,等. 无先验模型曲面的机器人打磨主动自适应在线轨迹预测方法[J]. 浙江大学学报(工学版), 2023, 57 (8): 1655—1666.

[13] 扈博琴,康庚. 基于 Stacking 集成算法的刀具剩余使用寿命自适应预测方法[J]. 制造业自动化, 2023, 45 (6): 210—214.

[14] 杨耿杰,韦先灿,高伟. 基于改进动态线损估计法的超差智能电表识别[J]. 电网技术, 2022, 46 (9): 3662—3671.

[15] 刘科研,贾东梨,王薇嘉,等. 考虑分布式光伏电源接入模式的低压配电网不平衡线损计算方法[J]. 电力建设, 2021, 42 (10): 129—138.