

# 灰狼算法优化 SVR 的 10kV 配网线损率预测研究

杨正宇<sup>1\*</sup>, 沈志强<sup>2</sup>, 郑成源<sup>3</sup>

(1. 云南电力试验研究院(集团)有限公司, 云南 昆明 650217;

2. 云南电网有限责任公司临沧供电局, 云南 临沧 677000;

3. 云南电网有限责任公司电力科学研究院, 云南 昆明 650217)

**摘要:**有效控制线损率不仅能为电力企业带来经济效益,而且能进一步提高一次能源的利用率。为了实现对 10 kV 配电网线损率的准确预测,提出基于灰狼算法(Gray Wolf Optimizer)优化支持向量机回归(Support Vector Regression)的 10 kV 配电网线损率预测方法;采用基于马氏距离的异常值检验及主成分分析法(Principal Components Analysis)对原始数据进行预处理,保证数据的清洁性的同时剔除原始数据中的冗余信息。利用 GWO 算法强搜索性的特点与 SVR 进行结合建立模型,通过与原始 SVR、ABC-SVR、BP 神经网络模型的预测结果进行比较,GWO-SVR 模型的预测精度最高,其均方根误差(RMSE)和平均绝对误差(MAE)分别为 0.233 2 和 0.195 8,最大相对误差为 14.4%,并且该模型具有最快的运算速度。

**关键词:**灰狼算法;10 kV 配电网;马氏距离;主成分分析;线损率

中图分类号:TP39

文献标识码:A

文章编号:1673-629X(2024)03-0035-06

doi:10.3969/j.issn.1673-629X.2024.03.006

## Research on Line Loss Rate Prediction of 10kV Distribution Network Based on SVR Optimized by Gray Wolf Algorithm

YANG Zheng-yu<sup>1\*</sup>, SHEN Zhi-qiang<sup>2</sup>, ZHENG Cheng-yuan<sup>3</sup>

(1. Yunnan Electric Power Test & Research Institute Group Co., Ltd., Kunming 650217, China;

2. Lincang Power Supply Bureau of Yunnan Power Grid Co., Ltd., Lincang 677000, China;

3. Electric Power Research Institute of Yunnan Power Grid Co., Ltd., Kunming 650217, China)

**Abstract:** Effective control of line loss rate can not only bring economic benefits to power enterprises, but also improve the utilization rate of primary energy. In order to achieve accurate prediction of 10kV distribution network line loss rate, a Support Vector Regression prediction method based on Gray Wolf Optimizer was proposed. The outlier test based on Mahalanobis distance and Principal Components Analysis are used to preprocess the original data to ensure the cleanliness of the data and eliminate the redundant information in the original data. The strong search ability of GWO algorithm was combined with SVR to establish the model. Compared with the prediction results of original SVR, ABC-SVR and BP neural network models, the prediction accuracy of GWO-SVR model was the highest, and its root mean square error (RMSE) and mean absolute error (MAE) were 0.233 2 and 0.195 8, respectively. The maximum relative error is 14.4%, and this model has the fastest computing speed.

**Key words:** gray wolf algorithm; 10kV distribution network; Mahalanobis distance; principal component analysis; line loss rate

## 0 引言

电网的线损率是一个综合性、全面性的评价指标,其不仅可以反映一个单位或一个区域的供电经济性,也可以间接反映供电的技术条件和管理水平<sup>[1]</sup>。有效控制线损率、降低线路损耗、实现电网经济运行是电力企业现代化管理的核心内容<sup>[2]</sup>,因此,对线损率进行准确预测,及时对高损线路进行巡检维护,有利于降低供电成本,保证电网经济稳定地运行。

近几年来,有关配电网线损、线损率的计算与预测研究变得愈发活跃<sup>[3-7]</sup>。传统常用的统计线损的理论计算方法有均方根电流法、平均电流法等。虽然线损的理论计算在一定条件下能够取得较好的效果,但是由于理论计算条件较为理想,现实中部分电力数据较难获取等问题,实际来说并不具有代表性。随着计算机、人工智能技术的发展及其在电力系统中的运用,许多新的方法被用于线损计算中<sup>[8-9]</sup>。

收稿日期:2023-01-04

修回日期:2023-05-10

基金项目:南方电网有限责任公司科技项目(YNKJXM20220166)

作者简介:杨正宇(1996-),男,硕士,助理工程师,通讯作者,研究方向为电能计量、线损分析、检测技术等。

该文以 10 kV 配电网运行数据为基础,对原始数据进行必要的预处理操作,以马氏距离为异常值的判定标准,采用卡方分布确定异常阈值,对原始数据中的异常值进行剔除,为下文的建模分析打下基础。然后通过主成分分析对所选特征进行降维处理,利用灰狼优化算法具有强搜索性、强遍历性的优点与支持向量机回归模型相结合,对支持向量机回归模型的惩罚因子  $c$  和核函数  $g$  进行优化<sup>[10-11]</sup>。之后将处理好的特征量作为输入建立模型,最终通过云南电网某供电所真实电力数据对模型的预测效果进行验证。

## 1 GWO-SVR 模型数学理论

### 1.1 支持向量机回归

相比于约束较为严格的 SVM 分类,回归则比较宽松<sup>[12-13]</sup>。对于回归问题,给定训练数据  $D = \{(x_1, y_1), (x_2, y_2), \dots, (x_m, y_m)\}$ ,需要构建一条以  $f(x)$  为中心,宽度为  $2\varepsilon$  的隔离带,当训练样本落入此隔离带时,认为预测是正确的,即仅当  $f(x)$  与  $y$  之间的差异绝对值大于  $\varepsilon$  时才计算损失。在图 1 中,认为落入两条虚线中的样本残差为零,也就是它们的误差是可以容忍的。需要做的就是找到这两条合适的虚线边界,目的是使在虚线外的样本到虚线的直线距离  $z$  最小,最后再对区域外的点进行回归,其中损失函数如式 1 所示:




图 1 支持向量机回归原理

$$l_\varepsilon(z) = \begin{cases} 0, & |z| \leq \varepsilon \\ |z| - \varepsilon, & |z| > \varepsilon \end{cases} \quad (1)$$

式中:  $z$  为数据点到  $f(x)$  的距离;  $\varepsilon$  为误差阈值。

通过引入松弛变量  $\xi_i$  和  $\hat{\xi}_i$  ( $\xi_i, \hat{\xi}_i \geq 0$ ),将 SVR 表示为:

$$\begin{aligned} \min_{\omega, \xi, \hat{\xi}} & \frac{1}{2} \|\omega\|^2 + c \sum_{i=1}^m (\xi_i + \hat{\xi}_i) \\ \text{s.t.} & f(x_i) - y_i \leq \varepsilon + \xi_i \\ & y_i - f(x_i) \leq \varepsilon + \hat{\xi}_i \end{aligned} \quad (2)$$

式中:  $\xi_i$  为预测值到缓冲区域上边界的距离,  $\hat{\xi}_i$  为预

测值到缓冲区域下边界的距离,  $\omega$  为决策面法向量,  $c$  为常数,  $m$  为数据点的数量。

在此基础上引入拉格朗日乘子并对其求偏导,并将结果带入 SVR 对偶问题,可得出 SVR 解的公式为:

$$f(x) = \sum_{i=1}^m (\hat{a}_i - a_i) x_i^T x + b \quad (3)$$

式中:  $\alpha_i, \hat{a}_i$  为拉格朗日乘子。

径向基核函数(RBF)是常用的核函数,其函数表达式为:

$$K(x_i, x_j) = \exp(-r \|x_i - x_j\|^2), r > 0 \quad (4)$$

式中:  $r$  为函数的宽度参数,控制了函数的径向作用范围。

### 1.2 灰狼优化算法的数学描述

在灰狼优化算法中,狼群中每一头灰狼代表了种群的一个潜在解。为了描述灰狼的社会等级,将  $\alpha$  狼的位置视为最优解;将  $\beta$  和  $\delta$  狼的位置分别作为优解和次优解;  $w$  狼的位置作为其余的候选解。在 GWO 算法中,由  $\alpha, \beta, \delta$  引导狼群搜索,而  $w$  跟随前面的 3 种狼。灰狼优化算法的原理如图 2 所示。




图 2 灰狼优化算法原理

灰狼狩猎时需要包围猎物,包围的数学描述为:

$$D = |C \bullet X_p(t) - X(t)| \quad (5)$$

$$X(t+1) = X_p(t) - A \bullet D$$

式中:  $t$  为当前迭代次数;  $A$  和  $C$  为协同系数向量;  $X_p$  为猎物的位置;  $X$  为灰狼的位置。该文引入一种随迭代次数增加而线性变化的收敛因子  $\alpha$ , 向量  $A$  和  $C$  与收敛因子  $\alpha$  的计算方式如下:

$$\begin{aligned} A &= 2\alpha \bullet r_1 - a \\ C &= 2 \bullet r_2 \\ \alpha &= 2 - it \times (2/\text{Maxit}) \end{aligned} \quad (6)$$

式中:  $\alpha$  的分量在迭代过程中从 2 线性减少到 0,  $it$  为当前的迭代次数,  $\text{Maxit}$  为设置的最大迭代次数,  $r_1, r_2$  是  $[0, 1]$  之间的随机向量。

在狩猎阶段中狩猎通常由  $\alpha$  狼引导,  $\beta$  和  $\delta$  也可能偶尔参与狩猎行为,在每次迭代过程中,保留迄今为止获得的最优的三个解 ( $\alpha, \beta, \delta$  的位置),迫使其他

狼 ( $w$ ) 根据最优的搜索位置采用以下公式对它们的位置进行更新:

$$\begin{aligned} D_\alpha &= |C_1 \cdot X_\alpha - X|, D_\beta = |C_2 \cdot X_\beta - X| \\ D_\delta &= |C_3 \cdot X_\delta - X|, X_1 = X_\alpha - A_1 \cdot D_\alpha \\ X_2 &= X_\beta - A_2 \cdot D_\beta, X_3 = X_\delta - A_3 \cdot D_\delta \end{aligned} \quad (7)$$

$$X(t+1) = \frac{X_1 + X_2 + X_3}{3}$$

式中:  $D_\alpha, D_\beta, D_\delta$  分别表示当前候选灰狼与最优三条狼之间的距离,  $C_1, C_2, C_3, A_1, A_2, A_3$  皆为系数向量,  $X_\alpha, X_\beta, X_\delta$  分别为三种狼的原始位置,  $X_1, X_2, X_3$  分别为三种狼更新后的位置。

为了描述接近猎物,根据式 6,通过逐渐减少  $\alpha$  的值,  $A$  的值也随之波动。当  $A$  的随机值在  $[-1, 1]$  中时,搜索狼可以是候选狼的当前位置和猎物之间的任何位置。灰狼主要根据  $\alpha, \beta$  和  $\delta$  狼的位置搜索,为了模拟搜索的分散性,利用  $A$  大于 1 或  $A$  小于 -1 的随机值来迫使搜索狼远离猎物,这样会使 GWO 算法强调勘探,更有利于全局搜索。

### 1.3 GWO-SVR 预测模型

基于 GWO-SVR 的线损率预测流程包括数据预处理、初始化种群、灰狼位置寻优等过程,具体步骤如下:

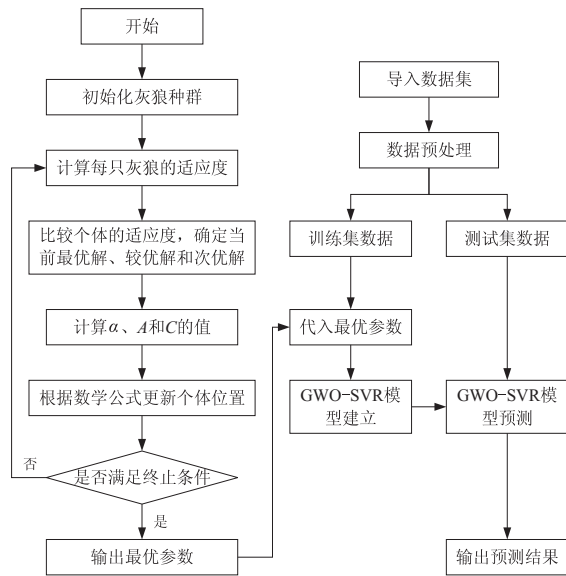


图 3 GWO 算法优化 SVR 模型流程

(1)数据预处理:对数据的预处理环节是分析研究的首要步骤,包括缺失值填补、异常值分析删减等操作,同时利用 PCA 对原始数据进行降维处理。

(2)设定算法初始值:此处所需设定的参数包括种群规模、最大迭代次数、数据维度以及 SVR 中核函数  $g$  以及惩罚因子  $c$  (取值范围)。

(3)模型中导入训练集数据,初始化种群,以适应度作为评价函数值,不断更新灰狼的位置信息,寻找参

数最优的灰狼坐标。

(4)以最大迭代次数为运行的截止条件,当运行次数达到设定值后,得到支持向量机回归最优参数,代入回归预测模型。

(5)模型中导入测试集数据,利用相应指标对模型的预测效果进行评价。

GWO 算法优化 SVR 模型的流程如图 3 所示。

## 2 数据预处理

### 2.1 基于马氏距离的异常值检验

在所获取的真实电力数据中,一般来说会存在数据重复以及数据缺失的情况,若不经数据的清洗而直接使用的话效果往往会适得其反。该文采用“热卡填充法”对原始数据中的缺失值进行填补,对于离群值采用删除相应值并采用缺失值的填补办法对其值进行修正处理。所收集的数据特征如表 1 所示。

表 1 模型输入输出特征类型

数据类别	编号	特征名称	单位
输入数据特征	1	变压器容量	kVA
	2	有功供电量	kWh
	3	无功供电量	kWh
	4	线路供电半径	m
	5	线路长度	m
	6	变压器的负载率	%
	7	线路投运年限	年
输出数据特征	8	线损率	%

与目前常用的聚类方法欧氏距离不同,马氏距离可以应对高维线性分布的数据中各维度间非独立、同分布的问题<sup>[14]</sup>。对于一个均值为  $\mu = (\mu_1, \mu_2, \dots, \mu_p)^T$ ,协方差矩阵为  $\Sigma$  的多变量矢量  $x = (x_1, x_2, \dots, x_p)^T$ ,其马氏距离为:

$$D_M(x) = \sqrt{(x - \mu)^T \Sigma^{-1} (x - \mu)} \quad (8)$$

马氏距离也可以定义为两个服从同一分布并且其协方差矩阵为  $\Sigma$  的随机变量:

$$d(\vec{x}, \vec{y}) = \sqrt{(\vec{x} - \vec{y})^T \Sigma^{-1} (\vec{x} - \vec{y})} \quad (9)$$

该文所采用的数据均来自云南电网某供电所,共涉及 10 条 10 kV 配电线路共计 1 200 组电力数据,根据置信水平  $\alpha=0.95$  对应卡方分布置信区间,以输入特征量确定检验的自由度为 7 (输入模型的特征个数),通过卡方分布计算可得卡方检验阈值为 14.07。由于马氏距离服从卡方分布,笔者认为马氏距离大于 14.07 的数据即为异常值并予以剔除,达到提高样本质量的目的。基于马氏距离的异常样本检测的结果示意图如图 4 所示。




图 4 马氏距离的异常样本检测的结果

## 2.2 数据降维处理

数据降维具有减少数据维度和需要的存储空间、节约模型训练计算时间、去掉冗余变量,提高算法的准确度等优点<sup>[15-16]</sup>,其通过一定的手段和方法,降维重组成一组新的维度较少的主成分综合指标,作为替代指标中原本的主成分数据集。表 2 给出了实际线损率数据经过 PCA 算法处理之后的前 4 个主成分的特征占比累计贡献率。

表 2 总方差解释

成分	初始特征量			提取荷载平方和		
	总计	方差百分比	累计 /%	总计	方差百分比	累计 /%
1	2.467	35.241	35.241	2.467	35.241	35.241
2	2.281	32.579	67.819	2.281	32.579	67.819
3	1.380	19.718	87.538	1.380	19.718	87.538
4	0.584	8.340	95.878	0.584	8.340	95.878
5	0.146	2.089	97.967	—	—	—
6	0.117	1.673	99.640	—	—	—
7	0.103	0.360	100.000	—	—	—

PCA 处理之后原始数据被重新组合成新的互不相关的特征量。由表 2 可知,前 4 个主成分的累计特征占比为 95.878%,大于 90%,也就是说明原始数据中绝大部分有效信息被成功提取。因此,选用这 4 个新的主成分数据来对原来所选的 7 维数据进行替代。经过数据重构后的主成分因子荷载如表 3 所示。

表 3 主成分因子荷载

主成分 1	主成分 2	主成分 3	主成分 4
0.321 57	-1.511 97	0.219 75	-0.060 28
-0.060 28	0.282 17	-1.815 34	0.948 55
-0.336 27	1.006 26	-1.041 68	1.169 33
0.098 43	-0.183 19	-2.274 63	0.486 29
1.634 93	0.617 53	0.893 33	-1.080 2
-2.265 13	0.741 19	0.741 19	0.741 19
-0.213 9	0.836 3	-1.153 54	1.488 24
-2.177 23	0.438 12	1.515 59	-0.182 65

续表 3

主成分 1	主成分 2	主成分 3	主成分 4
0.115 72	-0.981 64	0.633 45	0.220 87
...	...	...	...
-2.265 13	0.741 19	0.741 19	0.741 19
-0.213 9	0.836 3	-1.153 54	1.488 24

## 2.3 GWO-SVR 预测模型初始参数的选择

SVR 模型具有能处理高维非线性问题的优点,但是相应的运算和存储量都会有很大的消耗。在群智能优化算法中,种群数量的取值一般为 20~40,粒子数量越多,搜索范围越大,越容易找到全局最优解,但相应的算法运行时间也越长。为了保证模型的运算效率,该文初始种群规模选择 20,并且限制迭代次数最大为 100 代。

在支持向量机模型中,当所选参数趋于无穷大时,代表着不允许出现分类误差的样本存在,因为这将是一个过拟合问题,当所选参数趋于 0 时,不再关注分类是否正确,只要求间隔越大越好,那么将无法得到有意义的解且算法不会收敛。因此,灰狼优化算法针对的目标即 SVR 模型的参数(惩罚因子  $c$  和核函数  $g$ )需要在运算中给予限制,文中设定参数的取值范围在 0.01 至 100 之间。

文中初始数据设定情况如表 4 所示。

表 4 算法初始化参数设定

灰狼规模	参数取值		自变量维数	总迭代次数
	下界	上界		
20	0.01	100	2	100

## 3 实验结果及分析

### 3.1 预测模型评价指标

常用的评价指标包括均方根误差、平均绝对误差和相对误差,其计算方式如下所示:

$$\delta_{RMSE} = \sqrt{\frac{1}{m} * \sum_{i=0}^m (f_i - y_i)^2} \quad (10)$$

$$\delta_{MAE} = \frac{1}{m} * \sum_{i=0}^m |f_i - y_i| \quad (11)$$

$$\delta = (f_i - y_i) * 100\% \quad (12)$$

式中,  $m$  代表数据集的样本总量,  $f_i$  和  $y_i$  分别代表真实值和预测值。在模型运算结果的分析中,经常使用上述指标来评价所建立模型的优劣程度,预测结果的评价指标越小,说明测试集的预测精度越准确,也从侧面反映了所建模型是理想的。因此,将上述的评价指标用于之后的预测模型的性能评价之中。

### 3.2 基于支持向量机回归的线损率预测结果分析

文中使用留出法(Hold-Out)以 8 : 2 的比例划分

训练集以及测试集。经过支持向量机回归所得到的预测结果如图 5 所示。




图 5 SVR 模型预测值与真实值对比




图 6 SVR 模型预测残差




图 7 SVR 模型预测相对误差

通过图 5 可以看出,图中两条线分别代表线损率测试集的预测值以及真实值,在图中两线表现出重合度高忽低忽的画面,说明所建立的 SVR 模型虽然能在一定程度上对线损率进行预测,但是预测性能还有待提高。为了进一步描述模型的预测性能,文章引入了预测残差以及相对误差,如图 6 和图 7 所示。通过预测残差可以看出,在模型的预测过程中线损率残差虽然围绕 0 值上下波动,但是部分测试样本的波动范围过大,相对误差表现出其最大相对误差为 27.4%。通过利用上述所建立的评价指标计算可知,支持向量机回归预测模型的均方根误差为 0.389 1,平均绝对误差为 0.330 5。

### 3.3 灰狼算法优化支持向量机的线损率预测

文中选用均方误差作为优化的适应度函数值,其

适应度函数(目标函数值)如式 13 所示:

$$fitness_{MSE} = \frac{1}{m} * \sum_{i=0}^m (y_i - y_j)^2 \tag{13}$$

式中,  $m$  代表数据集的样本总量,  $y_i$  和  $y_j$  分别是真实值和预测值,适应度值越小说明模型的拟合程度越高。根据表 4 所设定参数对模型赋予初值,经过 10 次仿真运算求平均得到模型的适应度曲线如图 8 所示。




图 8 GWO-SVR 模型适应度曲线

由图 8 可以看出,在迭代次数设置为 100 次的情况下,模型经过 20 次搜索就能达到一个最优值附近,同时在搜索前期经过少数几次搜索就能寻找到更优的值,逐渐向最优值逼近,体现了灰狼优化算法的搜索性强,搜索范围广且利于跳出局部最优的优点,这也满足在模型建立时低成本、省时间的要求。使用 GWO-SVR 模型对实际线损率测试集数据进行仿真的结果如图 9 所示。




图 9 GWO-SVR 模型预测值与真实值对比

如图 9 所示,将 GWO-SVR 的线损率预测结果可视化,在 200 个测试集样本进行测试过程中,可以看到在样本实际测试的过程中的折线图基本重合,代表着预测值与实际值较为接近。图 10 为测试数据的残差,可看出测试数据的残差值围绕 0 上下波动,且大多数预测残差都在 0 值附近,说明预测的效果较为理想。根据上文所提及的评价指标来看,预测模型均方根误差为 0.233 2,平均绝对误差为 0.195 8。图 11 为预测模型的相对误差,图中显示最大的相对误差为 14.4%,相对于原本的支持向量机模型来说,GWO-SVR 模型具有更优异的预测性能,均方根误差与平均绝对误差相对于单一的 SVR 模型分别降低了 0.155 9

和 0.134 7, 并且最大相对误差都在 15% 以内。

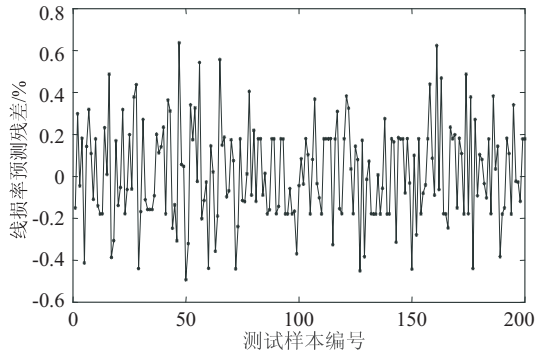


图 10 GWO-SVR 模型预测残差

为了验证文中模型在 10 kV 配电网线损率预测方面的优异性能, 表 5 为该模型与传统预测模型 SVR、




图 11 GWO-SVR 模型预测相对误差

BP 神经网络、ABC-SVR 对于同一样本的预测结果比较, 可以看出 GWO-SVR 模型具有最高的预测精度以及最快的运算速率。

表 5 各模型运算结果对比

模型类别	均方根误差	平均绝对误差	最大相对误差/%	运算时间/s	最优参数(c,g)
SVR	0.389 1	0.330 5	27.4	26.19	(9.088,82.312)
BP 神经网络	0.392 2	0.342 3	28.1	36.05	/
ABC-SVR	0.252 0	0.213 8	17.6	62.56	(5.822,95.948)
GWO-SVR	0.233 2	0.195 8	14.4	18.47	(4.103,98.263)

#### 4 结束语

提出基于灰狼算法优化支持向量机回归的 10 kV 配电网线损率预测方法, 利用主成分分析法对经过预处理之后的数据进行降维, 在提取数据有效信息的情况下减少模型的复杂程度, 最终利用灰狼优化算法对支持向量机回归的惩罚因子 c 和核函数 g 进行优化。通过仿真实验, 绘制出模型的预测值与实际值的对比图, 最后从模型的评价指标出发, 对比文中 4 类模型对于 10 kV 配电网线损率的预测性能, 验证了所建立的模型在 10 kV 配电网线损率预测方面的有效性。

#### 参考文献:

[1] 李海天. 基于 PSO-ESN 的线损模拟预测方法研究[D]. 北京: 华北电力大学(北京), 2018.

[2] 赵永红, 张旭, 程少华, 等. 基于关联度变权的台区理论线损水平评估方法研究[J]. 电力需求侧管理, 2020, 22(2): 39-43.

[3] 生西奎, 付强, 于洋, 等. 基于深度学习 GRU 网络的配电网理论线损计算方法[J]. 电测与仪表, 2021, 58(3): 54-59.

[4] 李敏, 王诚意, 蔡嘉辉, 等. 基于专家系统的台区线损异常智能诊断方法及应用[J]. 电力需求侧管理, 2021, 23(5): 81-85.

[5] 杨正宇, 韩彤, 赵振刚. 基于 ARIMA-GWO-SVR 组合模型的线损率时序预测[J]. 供用电, 2022, 39(7): 58-63.

[6] 徐云, 王福能. 采用 sEMG 的手势识别用 APSO/CS-SVM 方法[J]. 电子测量与仪器学报, 2020, 34(7): 1-7.

[7] 刘科研, 贾东梨, 王薇嘉, 等. 考虑负荷不平衡分布的低压配电网线损实用计算策略[J]. 电力需求侧管理, 2021, 23(6): 81-86.

[8] 张佳轩. 基于电力大数据的低压台区线损管理[D]. 汉中: 陕西理工大学, 2020.

[9] 师磊. 基于灰色关联和人工神经网络的配电网线损分析[D]. 长春: 长春工业大学, 2020.

[10] 张新生, 张琪. 基于改进 RFFS 和 GSA-SVR 的长输油管道腐蚀深度预测研究[J]. 系统工程理论与实践, 2021, 41(6): 1598-1610.

[11] 陈家瑞, 陈忠孝, 秦刚, 等. 基于 PSO 算法与 SVR 算法在企业直流配电网短期负荷预测的研究[J]. 国外电子测量技术, 2020, 39(12): 70-73.

[12] LIU Bing, JIN Yueqiang, LI Chaoyang. Analysis and prediction of air quality in Nanjing from autumn 2018 to summer 2019 using PCR - SVR - ARMA combined model[J]. Scientific Reports, 2021, 11(1): 52-54.

[13] On the mahalanobis distance classification criterion for a ventricular septal defect diagnostic system[J]. 医学诊断, 2020, 10(1): 42-50.

[14] 房祥忠. 卡方分布与卡方检验[J]. 中国统计, 2022(5): 29-31.

[15] 卢德龙, 王巨灏, 张颖, 等. 计及用户侧数据不确定性的台区线损粗糙算法[J]. 电力需求侧管理, 2020, 22(6): 33-38.

[16] 杨婷, 陈黎来, 李世纪, 等. 基于主成分分析-线性回归的光伏发电功率预测研究[J]. 南京工程学院学报: 自然科学版, 2022, 20(1): 77-83.