

基于特征选择和优化极限学习机的 短期电力负荷预测

商立群, 李洪波, 侯亚东, 黄辰浩, 张建涛
(西安科技大学电气与控制工程学院, 710054, 西安)

摘要: 针对负荷预测过程中特征量难以确定以及极限学习机(ELM)存在因随机产生的初始权值和阈值导致输出稳定性低的问题,提出了基于格拉姆施密特正交化与皮尔逊相关性分析相结合的特征选择方法(GSO-PCA)和改进灰狼算法(IGWO)优化 ELM 的短期电力负荷预测模型(IGWO-ELM)。对两种不同类型的特征分别使用 GSO 算法和 PCA 进行优选,并根据平均绝对百分比误差(MAPE)确定最优特征集,与传统的经验特征选择、最大互信息系数特征选择、随机森林特征选择比较,GSO-PCA 特征选择的 MAPE 分别降低了 1.3%、0.55%和 0.83%,验证了其优越性;将 Tent 混沌映射和粒子群优化算法(PSO)融入到灰狼优化算法中,得到 IGWO,并利用两种典型的测试函数对 IGWO 性能进行测试,证明了其具有更强的寻优能力;使用 IGWO 算法对 ELM 的初始权值和阈值进行动态优化,建立 IGWO-ELM 短期负荷预测模型。将拟合优度检验系数、平均绝对误差、均方根误差和 MAPE 作为评价指标,结合实例分析,与传统的模型进行比较。仿真结果表明:所提预测模型得到的 4 个评价指标分别为 0.997 8、54.90 kW、72.02 kW 和 1.52%,明显优于其他模型,验证了所提模型的有效性和优越性。

关键词: 短期电力负荷预测;极限学习机;灰狼优化算法;粒子群优化算法;Tent 混沌映射;格拉姆施密特正交化;皮尔逊相关性分析

中图分类号: TM715 **文献标志码:** A

DOI: 10.7652/xjtuxb202204018 **文章编号:** 0253-987X(2022)04-0165-11



OSID 码

Short-Term Power Load Forecasting Based on Feature Selection and Optimized Extreme Learning Machine

SHANG Liqun, LI Hongbo, HOU Yadong, HUANG Chenhao, ZHANG Jiantao
(School of Electrical and Control Engineering, Xi'an University of Science and Technology, Xi'an 710054, China)

Abstract: For the difficulty in determining the feature quantity and the low output stability of the extreme learning machine (ELM) due to randomly generated initial weights and thresholds during load forecasting, it is proposed in this paper that the Gram-Schmidt orthogonalization and Pearson correlation analysis (GSO-PCA) and improved gray wolf optimization (IGWO) algorithm be used to optimize the short-term power load forecasting model of ELM (IGWO-ELM). GSO and PCA are used for optimal selection of two distinct features respectively, and the mean absolute percentage error (MAPE) is based for determination of the optimal feature set. MAPE in GSO-PCA is 1.3%, 0.55% and 0.83% lower respectively compared with that in traditional experience, maximum information coefficient and random forest for feature selection. This

verifies its superiority. The Tent chaotic mapping and particle swarm optimization (PSO) algorithm are integrated into the gray wolf optimization algorithm to obtain IGWO algorithm which is tested with two typical test functions and proved with better optimization capability. The IGWO algorithm is used to dynamically optimize initial weights and threshold of the ELM and establish IGWO-ELM short-term power load forecasting model. This established model is then compared with a traditional model in terms of four evaluation indexes, i. e., goodness of fit test coefficient, mean absolute error, root mean square error and MAPE and in line with case study. The simulation results show that these four indexes are 0.997 8, 54.90 kW, 72.02 kW and 1.52% and are significantly better other models. This verifies the effectiveness and superiority of the proposed model.

Keywords: short-term power load forecasting; extreme learning machine; gray wolf optimization algorithm; particle swarm optimization algorithm; Tent chaotic mapping; Gram-Schmidt orthogonalization; Pearson correlation analysis

电力负荷预测作为电网规划中的重要组成部分,对于电力系统安全经济运行具有重大意义。精确的电力负荷预测,特别是短期电力负荷预测,既能保障人们用电可靠和电网安全稳定运行,也能使电力行业的效益极大地提升^[1-2]。

早期的电力负荷预测方法是基于数学统计理论中的模型提出的,如趋势外推法、时间序列法、回归分析法、灰色系统法等传统预测方法^[3-4]。由于这些预测方法的模型单一,且对于时间序列的平稳性要求较高,使得预测的结果误差大、精度低^[5],随着人工智能技术的发展,机器学习及人工智能等方面的算法被广泛应用于电力负荷预测领域,如专家系统、支持向量回归、人工神经网络等^[6-9]。专家系统缺乏自主学习能力,负荷预测精度会受其对突发性事件和不断变化的条件适应性较差的影响^[10-11]。支持向量回归采用结构风险最小化原则解决小样本数据,预测效果较好,但其核函数参数的选取限制了最终的预测精度^[12-13]。人工神经网络相对复杂,它要通过反向传播以调整网络权值和阈值,收敛速度慢,需要消耗大量的训练时间才能得到较为准确的预测结果^[14-15]。极限学习机(ELM)的提出很大程度上弥补了传统的人工神经网络的缺点,在学习速率和泛化能力方面具有较大的优势,只需随机产生输入层与隐含层之间的权值以及隐含层的阈值并训练对电力负荷进行预测,但利用随机数作为初始参数会导致 ELM 的稳定性下降^[16]。准确选择合适的特征对于短期电力负荷预测尤为关键,而短期电力负荷原始时间序列的历史负荷特征及外部影响因素多样而复杂,仅依靠机器学习进行预测很难达到更高的精

度,因此对原始数据进行优选和降维十分重要。

针对负荷预测的特征选择问题,文献[17]利用核主成分分析法对外部气象因素进行优选,但并未对历史负荷特征进行最优选择。文献[18]利用最大互信息系数对历史负荷特征及外部影响因素进行筛选,取得了较好的结果,但筛选后的特征中仍具有较大的信息冗余,且未对最优特征维数进行确定和检验。针对 ELM 模型在预测时产生的稳定性问题:文献[19]利用蝙蝠算法对 ELM 的隐含层节点数进行优化,但并未对权值和阈值进行优化;文献[20]利用改进遗传算法对 ELM 的权值和阈值进行优化,一定程度上提高了 ELM 的稳定性,但算法过程较为烦琐;文献[21]利用多目标粒子群算法优化 ELM 的参数权值和阈值,但单一的粒子群算法存在易陷入局部最优解而导致参数优化不佳的缺点,会对 ELM 的稳定性产生不良影响。

针对这些问题,本文提出基于格拉姆-施密特正交化与皮尔逊相关性分析相结合特征选择方法(GSO-PCA)和改进灰狼算法(IGWO)优化极限学习机的短期电力负荷预测模型(IGWO-ELM)。分别使用 GSO 和 PCA 对两种不同类型特征进行优选,并根据平均绝对百分比误差(MAPE)确定最优特征集,这样既可保留大量的负荷原始数据信息,也可避免负荷信息的重叠,与常见的特征选择方法比较,验证了其优越性;将 Tent 混沌映射和粒子群算法(PSO)融入到灰狼算法中,得到 IGWO 算法,并使用两种典型的测试函数验证了 IGWO 算法具有更强的寻优能力;利用 IGWO 算法对 ELM 的参数进行动态优化,建立 IGWO-ELM 短期负荷预测模

型;将同一最优特征集分别输入到 ELM、GA-ELM、PSO-ELM、GWO-ELM 和 IGWO-ELM 模型中进行短期电力负荷预测,并对所得结果进行比较与分析。实例分析验证了本文所提的负荷预测模型具有更高的预测精度和更强的泛化能力。

1 GSO-PCA 特征选择方法

电力负荷具有显著的特性和变化规律,但一些外部因素会对它产生重大影响,如气象、日期类型等,因此要精确预测未来的负荷变化情况必须充分考虑负荷自身的变化规律以及相关影响因素^[22]。本文将负荷预测特征分为两大类:反映负荷自身变化规律的特征(预测时刻之前的负荷值)与外部影响因素特征(气象、日期类型等)。本文分别使用 GSO 算法和 PCA 对两种不同类型特征进行优选,并根据 MAPE 确定最优特征集。在保证预测精度的前提下,既提取了表达负荷的有效信息,避免了冗余信息的出现,也弥补了经验特征选择方法标准缺乏的不足。

1.1 GSO 算法原理

GSO 算法是一种前向选择方法,可根据研究目标之间的正交性对特征进行筛选并排序^[23]。为了选择与输出量相关的最佳特征,计算每个特征 $\mathbf{x}_k$ 与其输入量 $\mathbf{y}$ 的余弦值作为评价指标,表达式为

$$\cos\varphi_k = \frac{\langle \mathbf{x}_k, \mathbf{y} \rangle}{\|\mathbf{x}_k\| \|\mathbf{y}\|} \tag{1}$$

式中: $\mathbf{x}_k=[x_{k1}, x_{k2}, \cdots, x_{km}]^T$, x_{km} 为第 m 个样本的第 k 个特征量; $\mathbf{y}=[y_1, y_2, \cdots, y_m]^T$ 为输出量; φ_k 为第 k 个特征量与输出量 $\mathbf{y}$ 之间的夹角; $\langle \mathbf{x}_k, \mathbf{y} \rangle$ 为 $\mathbf{x}_k$ 和 $\mathbf{y}$ 之间的内积。 $\cos\varphi_k$ 越接近 1,则输入特征与输出量越相关;反之,则越不相关。因此,在筛选过程中,选择评价指标大的特征作为目标的最相关特征,本文将满足 $\cos\varphi_k \geq 0.7$ 的负荷特征作为最相关特征。与经验特征选择方法进行负荷特征选择相比, GSO 算法选择的负荷特征更能体现负荷的变化规律,避免了负荷信息冗余的出现。

- 基于 GSO 算法的负荷特征选择方法步骤如下。
- 步骤 1** 将历史负荷时间序列分为训练集和测试集,根据测试集中的样本确定各预测时刻的真实负荷值。
- 步骤 2** 将数据归一化后,构造每个预测日的特征量矩阵和输出量矩阵;特征量矩阵由各历史负荷特征组成,输出量矩阵由预测日各时刻负荷值组成。
- 步骤 3** 根据相关条件对各历史负荷特征进行筛选并排序,获得最相关负荷特征。

基于 GSO 算法的负荷特征选择流程见图 1。




图 1 基于 GSO 算法的负荷特征选择流程

Fig. 1 The process of load feature selection based on GSO algorithm

1.2 PCA 原理

电力负荷预测除了与自身的变化规律相关,与外部影响因素也密不可分。PCA 是一种被广泛用来描述变量相关性的方法,其核心思想是通过皮尔逊相关系数(PCC)来反映变量的相关程度。

设 $X_i=\{x_i(1), x_i(2), \cdots, x_i(k), \cdots, x_i(n)\}$ 为外部影响因素集合, i 代表第 i 个影响因素, k 代表第 k 天, $Y_j=\{y_j(1), y_j(2), \cdots, y_j(k), \cdots, y_j(n)\}$ 为负荷集合, j 代表第 j 个负荷类型,则 X_i 与 Y_j 之间的皮尔逊相关系数表达式为

$$r_{X_i, Y_j} = \frac{\sum_{k=1}^n [x_i(k) - \bar{x}_i][y_j(k) - \bar{y}_j]}{\sqrt{\sum_{k=1}^n [x_i(k) - \bar{x}_i]^2} \sqrt{\sum_{k=1}^n [y_j(k) - \bar{y}_j]^2}} \tag{2}$$

式中: $x_i(k)$ 、 $y_j(k)$ 分别为第 i 个影响因素第 k 天的值和第 j 个影响因素第 k 天的值; $\bar{x}_i$ 、 $\bar{y}_j$ 分别为第 i 个影响因素的平均值和第 j 个影响因素的平均值。

皮尔逊相关系数 $r_{X,Y}$ 取值范围为 $[-1, 1]$, $|r_{X,Y}|$

越大,则 X 与 Y 之间的相关度越强。具体相关程度关系如表 1 所示。本文选择皮尔逊相关系数大于等于 0.4 的影响因素构建特征集。

表 1 皮尔逊相关系数相关程度关系
Table 1 Related degree relationship table of Pearson correlation coefficient

$ r_{X,Y} $	相关程度
0~0.2	极弱
0.2~0.4	弱
0.4~0.6	中等
0.6~0.8	强
0.8~1.0	极强

1.3 GSO-PCA 特征选择工作流程




图 2 基于 GSO-PCA 特征选择流程
Fig. 2 The process of feature selection based on the GSO-PCA

2 极限学习机原理

极限学习机是一种基于前馈神经网络构建的机器学习方法。ELM 的基本原理是随机生成输入层与隐含层之间连接的权值以及隐含层节点的阈值,

并设置隐含层神经元数,然后经过简单的矩阵计算便可获得唯一最优解的过程。与传统的前馈神经网络算法相比,ELM 具有学习速率快、泛化性能强等优点,它不仅能解决回归、拟合等问题,还在分类、模式识别等领域得到了广泛的应用。

ELM 的训练模型为单隐含层前馈神经网络结构,设 N 组不同的样本 $\{(\mathbf{x}_i, \mathbf{t}_i)\}_{i=1}^N$, 其中 $\mathbf{x}_i = [x_{i1}, x_{i2}, \dots, x_{im}]^T \in \mathbb{R}^m$ 为输入量, $\mathbf{t}_i = [t_{i1}, t_{i2}, \dots, t_{in}]^T \in \mathbb{R}^n$ 为输出量。输入层节点数为 m , 隐含层节点数为 M , 输出层节点数为 n , $g(\cdot)$ 为隐含层神经元的激活函数, b_i 为隐含层神经元的阈值。

极限学习机的数学模型为

$$\sum_{j=1}^M \beta_j g(\omega_j \mathbf{x}_i + b_j) = \mathbf{t}_i, \quad i = 1, 2, \dots, N \quad (3)$$

式中: $\omega_i = [\omega_{i1}, \omega_{i2}, \dots, \omega_{im}]$ 为输入权值矩阵; $\beta_i = [\beta_{i1}, \beta_{i2}, \dots, \beta_{in}]^T$ 为隐含层输出权值矩阵; $\mathbf{t}_j = [t_{j1}, t_{j2}, \dots, t_{jn}]^T$ 为网络输出矩阵。式(3)通过一系列的推导可得

$$\mathbf{H}\boldsymbol{\beta} = \mathbf{T} \quad (4)$$

式中: $\mathbf{H} = \begin{bmatrix} g(\omega_1 \mathbf{x}_1 + b_1) & \dots & g(\omega_M \mathbf{x}_1 + b_M) \\ \vdots & & \vdots \\ g(\omega_1 \mathbf{x}_N + b_1) & \dots & g(\omega_M \mathbf{x}_N + b_M) \end{bmatrix}_{N \times M}$ 为隐含层输出矩阵; $\boldsymbol{\beta}_{M \times n} = [\boldsymbol{\beta}_1, \boldsymbol{\beta}_2, \dots, \boldsymbol{\beta}_M]^T$ 为输出权值矩阵; $\mathbf{T}_{N \times n} = [\mathbf{T}_1, \mathbf{T}_2, \dots, \mathbf{T}_N]^T$ 为目标输出矩阵。

ELM 的学习过程相当于一个非线性优化问题。当激活函数无限可微时,ELM 可以随机选择输入权值和隐含层的阈值,且隐含层的输出矩阵在训练过程中保持不变。此时,ELM 的学习过程可等价求最小二乘解,其解可表示为

$$\boldsymbol{\beta}^* = \mathbf{H}^+ \mathbf{T} \quad (5)$$

式中 $\mathbf{H}^+$ 为隐含层输出矩阵 $\mathbf{H}$ 的 Moore-Penrose 广义逆。

3 灰狼算法及其改进

3.1 基本灰狼算法

灰狼优化(GWO)算法^[24]是一种新型的群智能优化算法,其灵感来源于自然界中灰狼种群的严格社会等级制度和捕食行为。自然界中的灰狼种群分为 4 个等级,从高到低依次为 α 狼、 β 狼、 δ 狼、 ω 狼。 α 狼、 β 狼、 δ 狼为灰狼领导层,且数量仅为一只,对狼群的狩猎起领导和决策作用,其余均为 ω 狼,配合灰狼领导层搜索猎物的工作。算法核心是利用 ω 狼在搜索猎物过程中的不同位置,与上层狼群位置

进行比较,将更优的位置赋予上层狼群,最终达到寻优的目的。设灰狼种群中有 N 头狼,在 d 维空间内搜索,则第 i 头灰狼在的位置为 $\mathbf{x}_i = [x_{i,1}, x_{i,2}, \dots, x_{i,d}]^T$ 。基本灰狼算法描述如下。

(1) 猎物位置确定。在狩猎的过程中,猎物所在的位置更接近灰狼领导层,因此 ω 狼可根据灰狼领导层的位置确定猎物的位置,表达式为

$$\begin{cases} \mathbf{D}_\alpha = | \mathbf{C}_1 \mathbf{X}_\alpha(t) - \mathbf{X}(t) | \\ \mathbf{D}_\beta = | \mathbf{C}_2 \mathbf{X}_\beta(t) - \mathbf{X}(t) | \\ \mathbf{D}_\delta = | \mathbf{C}_3 \mathbf{X}_\delta(t) - \mathbf{X}(t) | \\ \mathbf{C}_i = 2\mathbf{r}_2, i = 1, 2, 3 \end{cases} \quad (6)$$

式中: $\mathbf{X}_\alpha(t)$ 、 $\mathbf{X}_\beta(t)$ 、 $\mathbf{X}_\delta(t)$ 分别为灰狼领导层 α 狼、 β 狼、 δ 狼的位置向量; $\mathbf{D}_\alpha$ 、 $\mathbf{D}_\beta$ 、 $\mathbf{D}_\delta$ 分别为 ω 狼与灰狼领导层 α 狼、 β 狼、 δ 狼之间的距离向量; $\mathbf{X}(t)$ 为当前 ω 狼的位置向量; $\mathbf{C}_1$ 、 $\mathbf{C}_2$ 、 $\mathbf{C}_3$ 均为系数向量,分别代表 ω 狼与灰狼领导层 α 狼、 β 狼、 δ 狼之间的搜寻距离权重; $\mathbf{r}_2$ 为区间 $[0, 1]$ 的随机向量。

(2) 灰狼位置更新。当灰狼领导层 α 狼、 β 狼、 δ 狼的位置确定后,需要对领导层周围的猎物进行围捕,表达式为

$$\begin{cases} \mathbf{X}_1(t+1) = \mathbf{X}_\alpha(t) - \mathbf{A}_1(\mathbf{D}_\alpha) \\ \mathbf{X}_2(t+1) = \mathbf{X}_\beta(t) - \mathbf{A}_2(\mathbf{D}_\beta) \\ \mathbf{X}_3(t+1) = \mathbf{X}_\delta(t) - \mathbf{A}_3(\mathbf{D}_\delta) \\ \mathbf{X}_4(t+1) = \frac{\mathbf{X}_1(t+1) + \mathbf{X}_2(t+1) + \mathbf{X}_3(t+1)}{3} \\ \mathbf{A}_i = 2a\mathbf{r}_1 - a, i = 1, 2, 3 \\ a = 2\left(1 - \frac{t}{T_{\max}}\right) \end{cases} \quad (7)$$

式中: $\mathbf{X}(t+1)$ 为 ω 狼更新后的位置向量; $\mathbf{A}_1$ 、 $\mathbf{A}_2$ 、 $\mathbf{A}_3$ 均为系数向量,分别代表 ω 狼与灰狼领导层 α 狼、 β 狼、 δ 狼之间的位置距离权重; $\mathbf{r}_1$ 为区间 $[0, 1]$ 的随机向量; $T_{\max}$ 为最大迭代次数。

当猎物停止移动时,灰狼种群会对猎物进行攻击,即寻得最优值。 a 、 $\mathbf{A}$ 、 $\mathbf{C}$ 在相应区间内发生变化时,每迭代一次,灰狼种群个体就会更新位置,直至接近并寻得猎物(最优值)。

3.2 改进灰狼算法

3.2.1 Tent 混沌映射

Tent 映射是一种分段混沌映射函数,其数学表达式为

$$X_{n+1} = \begin{cases} \frac{X_n}{a}, & 0 \leq X_n < a \\ \frac{1-X_n}{1-a}, & a \leq X_n < 1 \end{cases} \quad (8)$$

式中 a 为 $[0, 1]$ 的常数。若 $X_{n+1} > 1$, 则 X_{n+1} 返回值为 1; 若 $X_{n+1} < 0$, 则 X_{n+1} 返回值为 0。

由于基本灰狼算法是采用随机初始化的方法来确定种群初始位置的,导致灰狼个体在初始解空间内分布不均,极大地影响了灰狼算法的整体求解性能。混沌序列时常被运用于优化搜索问题,研究表明, Tent 混沌映射得到的序列在随机性、均匀性、遍历性等方面相比于其他混沌映射具有较大的优势^[25]。因此,本文采用 Tent 混沌映射产生的序列对灰狼种群初始化,有利于使初始的种群位置在初始解空间内分布更加均匀、范围更广。

3.2.2 粒子群优化算法

粒子群优化算法是一种传统的智能优化算法,其原理是空间中的粒子群通过不断迭代,跟踪个体最优值和全局最优值这两个极值,以更新自己的位置和速度,直至寻得满足终止条件的最优值。更新位置和速度表达式为

$$\begin{cases} \mathbf{V}_i^{k+1} = \omega \mathbf{V}_i^k + c_1 r_1 (\mathbf{P}_{\text{best}}^k - \mathbf{X}_i^k) + c_2 r_2 (\mathbf{G}_{\text{best}}^k - \mathbf{X}_i^k) \\ \mathbf{X}_i^{k+1} = \mathbf{X}_i^k + \mathbf{V}_i^{k+1} \end{cases} \quad (9)$$

式中: k 为当前迭代数; $\mathbf{P}_{\text{best}}^k$ 为个体最优位置向量; $\mathbf{G}_{\text{best}}^k$ 为全局最优位置向量; ω 为取值非负的惯性因子,代表粒子群的全局寻优能力; c_1 和 c_2 均为取值非负的加速因子,前者为个体学习因子,后者为全局学习因子; r_1 和 r_2 均为 $[0, 1]$ 的随机数。

灰狼算法本身具有一定的位置优化能力,但其在寻优过程中缺少群体位置与个体位置的交流,因此易陷入局部最优解。PSO 算法具有易实现、收敛速度快且对控制参数具有较强的鲁棒性等优点。因此,将粒子群优化算法融合到灰狼算法中,通过粒子群的位置更新来代替灰狼种群最终的位置更新,使得灰狼种群在寻优过程中具有更好的记忆能力,并在灰狼位置更新时加入 ω 惯性因子,以提高灰狼算法的局部搜索能力。由此,式(6)转化为

$$\begin{cases} \mathbf{D}_\alpha = | \mathbf{C}_1 \mathbf{X}_\alpha(t) - \omega \mathbf{X}(t) | \\ \mathbf{D}_\beta = | \mathbf{C}_2 \mathbf{X}_\beta(t) - \omega \mathbf{X}(t) | \\ \mathbf{D}_\delta = | \mathbf{C}_3 \mathbf{X}_\delta(t) - \omega \mathbf{X}(t) | \\ \mathbf{C}_i = 2\mathbf{r}_2, i = 1, 2, 3 \\ \omega = 0.5 + \theta/2 \end{cases} \quad (10)$$

式中 θ 为 $[0, 1]$ 内的随机数。式(9)可转化为

$$\begin{cases} \mathbf{V}_i^{k+1} = \omega [\mathbf{V}_i^k + c_1 r_1 (\mathbf{X}_1 - \mathbf{X}_i^k) + \\ c_2 r_2 (\mathbf{X}_2 - \mathbf{X}_i^k) + c_3 r_3 (\mathbf{X}_3 - \mathbf{X}_i^k)] \\ \mathbf{X}_i^{k+1} = \mathbf{X}_i^k + \mathbf{V}_i^{k+1} \end{cases} \quad (11)$$

式中： $\mathbf{X}_1$ 、 $\mathbf{X}_2$ 、 $\mathbf{X}_3$ 为 ω 狼群的位置向量； $\mathbf{X}_i^{k+1}$ 为灰狼种群更新后的位置向量。

改进灰狼优化算法流程如图 3 所示。




图 3 IGWO 算法流程

Fig. 3 The process of IGWO algorithm

3.3 IGWO 算法性能测试

为了测试 IGWO 算法的性能，本文采用两种典型的单峰和多峰测试函数，并与 PSO 算法和基本的 GWO 算法进行对比。测试函数表达式为

$$f_1(x) = \sum_{i=1}^n |x_i| + \prod_{i=1}^n |x_i| \quad (12)$$

$$f_2(x) = \frac{1}{4\,000} \sum_{i=1}^n x_i^2 - \prod_{i=1}^n \cos\left(\frac{x_i}{\sqrt{i}}\right) + 1 \quad (13)$$

不同测试函数的取值范围、最优解等信息如表 2 所示，不同算法的参数设置如表 3 所示。

将算法的最大迭代数 $T_{\max}$ 设置为 1 000，种群规模 N 设置为 30。对于测试函数，在迭代数一定时，平均值可以反映算法的寻优精度，而最优值和标准

表 2 测试函数信息

Table 2 Information of test function

函数	类型	维度	取值范围	最优解
f_1	Schwefel	30	$[-10, 10]$	0
f_2	Griewank	30	$[-600, 600]$	0

表 3 不同算法的参数设置

Table 3 Parameter settings of different algorithms

算法	参数设置
PSO	$c_1 = c_2 = 2, \omega = 0.8$
GWO	a 从 2 线性递减至 0, $r_1, r_2 \in [0, 1]$
IGWO	a 从 2 线性递减至 0, $r_1, r_2 \in [0, 1]$ $c_1 = c_2 = 2, \omega = 0.5 + \theta/2$

方差可以反映算法的稳定性和鲁棒性。为避免单次运行结果所带来的偏差，本实验分别对 2 个测试函数独立运行 30 次，得到各测试函数的最优值、平均值以及标准方差。测试函数优化结果比较见表 4。

表 4 不同测试函数优化结果对比

Table 4 Comparison of optimization results of different test functions

函数	算法	最优值	平均值	标准方差
f_1	PSO	$7.475\,8 \times 10^{-7}$	0.574 7	8.689 6
	GWO	$8.763\,7 \times 10^{-14}$	0.312 3	5.288 9
	IGWO	$4.875\,8 \times 10^{-17}$	0.115 2	3.546 2
f_2	PSO	$6.194\,0 \times 10^{-6}$	1.663 9	10.757 5
	GWO	$3.856\,2 \times 10^{-14}$	0.427 0	0.114 5
	IGWO	0	0.118 3	0.003 4

由表 4 可知，IGWO 算法优化得到的最优值更接近真实最优解，且平均值和标准方差小于 PSO 算法和 GWO 算法优化的结果。相较于 PSO 算法和基本的 GWO 算法，IGWO 算法具有更好的稳定性和寻优能力，能更快速而准确地得到最优解。

4 IGWO-ELM 短期电力负荷预测模型

在传统的 ELM 中，输入层与隐含层之间连接的权值以及隐含层节点的阈值是随机生成的，这大大节省了 ELM 的训练时间，但也不可避免地会出现产生的随机值并非最优的情况。这一方面使 ELM 相较于其他人工神经网络需要更多的隐含层神经元，另一方面使得到的隐含层输出矩阵出现较大偏差，进而使 ELM 的泛化能力大大减弱，输出也极不稳定。因此，对 ELM 的权值和阈值进行优化

十分必要。

本文采用 IGWO 算法对 ELM 参数进行优化,利用 IGWO 算法的全局及局部寻优能力,找出最优的权值和阈值参数。将优化后的参数代入到 ELM 中对短期电力负荷进行预测。IGWO-ELM 预测模型建立步骤如下。

步骤1 参数初始化。设置灰狼种群数量 N 、种群维度 D 、最大迭代数 $T_{\max}$ 。

步骤2 初始化灰狼种群。使用式(8)对灰狼种群初始化。

步骤3 计算参数 α 、 A 、 C ,将所有权值和阈值的组合作为每个灰狼个体的位置,并计算每一匹狼的适应度。本文将训练集中实际值和预测值之间的均方根误差作为适应度函数,适应度排名前3的分别作为 α 狼、 β 狼、 δ ,其余均为 ω 狼。

步骤4 利用式(10)更新灰狼种群个体的位置,并更新参数 α 、 A 、 C 。

步骤5 引入粒子群优化算法,更新灰狼种群个体的位置。利用式(11)对灰狼种群个体位置进行更新。

步骤6 计算灰狼新位置的适应度,并与上一次迭代的适应度比较。若适应度优于上一代,则更新,否则不变。

步骤7 判断是否已达到最大迭代数。若是则结束,并输出最优权值和阈值的组合,否则跳转至步骤3。

步骤8 利用优化后的 ELM 模型对短期电力负荷进行预测,并对结果进行分析。

基于 IGWO-ELM 的短期电力负荷预测流程如图4所示。

5 实例分析及仿真实验对比

本文采用第九届电工杯数学建模提供的实例数据集,从中选取2014年1月1日至2014年12月31日的电力负荷及气象数据,采样周期为15 min,数据集共有35 040条负荷数据。选择常用的负荷预测评价指标,将本文 IGWO-ELM 预测模型与传统 ELM、GA-ELM、PSO-ELM 以及 GWO-ELM 预测模型进行对比分析,验证本文模型的有效性和优越性。

5.1 数据归一化及评价指标

为避免因变量间的数量级不同而产生误差,对数据进行预处理,将数据统一归一化至 $[0,1]$ 。

为了更好地评估不同负荷预测模型的精度,本文选用4种常用的负荷预测评价指标,即拟合优度检验系数 R^2 、平均绝对误差、均方根误差和平均绝对百分比误差,表达式分别为




图4 基于 IGWO-ELM 的短期电力负荷预测流程

Fig.4 The process of short-term power load forecasting based on IGWO-ELM

$$R^2 = \frac{\sum_{i=1}^m (\hat{y}_i - \bar{y}_i)^2}{\sum_{i=1}^m (y_i - \bar{y}_i)^2} \quad (14)$$

$$e_{MAE} = \frac{1}{m} \sum_{i=1}^m |\hat{y}_i - y_i| \quad (15)$$

$$e_{RMSE} = \sqrt{\frac{1}{m} \sum_{i=1}^m (\hat{y}_i - y_i)^2} \quad (16)$$

$$e_{MAPE} = \frac{1}{m} \sum_{i=1}^m \frac{|\hat{y}_i - y_i|}{y_i} \times 100\% \quad (17)$$

式中: m 为样本数; y_i 为待预测样本的真实值; $\bar{y}_i$ 为待预测样本真实值的均值; $\hat{y}_i$ 为模型预测值。这些评价指标中, R^2 越接近1, e_{MAE} 、 e_{RMSE} 和 e_{MAPE} 越小,则表示拟合效果越好,即模型的预测精度越好。

5.2 GSO-PCA 特征选择

利用 GSO 算法优选出最相关负荷特征。基于现有相关文献研究^[26-28],构建原始负荷特征集,共37个,其中包括预测时刻前几个小时的负荷值、前几日或前几周同一时刻的负荷值。具体历史负荷特征如表5所示。本文研究短期电力负荷预测,故以预测日为1天的特征选择为例。首先将样本数据进行归一化处理,然后利用 GSO 算法筛选出最相关的

负荷特征,结果表 6。

表 5 历史负荷特征
Table 5 Historical load features

负荷特征	含义
$y_1 \sim y_6$	预测日前 1~6 天同一时刻负荷值
$y_7 \sim y_9$	预测日前 1~3 周同一时刻负荷值
$y_{10} \sim y_{14}$	预测日前 8~12 天同一时刻负荷值
$y_{15} \sim y_{37}$	预测日前 1~23 小时负荷值

表 6 GSO 算法优选的最相关负荷特征
Table 6 The most relevant load features preferred by the GSO algorithm

排序	负荷特征	$\cos\varphi_k$	排序	负荷特征	$\cos\varphi_k$
1	y_8	0.999 0	13	y_{13}	0.990 1
2	y_7	0.998 5	14	y_6	0.986 2
3	y_9	0.997 4	15	y_{15}	0.939 9
4	y_1	0.992 2	16	y_{37}	0.920 2
5	y_{10}	0.991 6	17	y_{16}	0.860 5
6	y_{11}	0.990 8	18	y_{36}	0.844 8
7	y_2	0.990 8	19	y_{17}	0.791 6
8	y_3	0.990 7	20	y_{35}	0.786 1
9	y_{12}	0.990 5	21	y_{34}	0.739 5
10	y_5	0.990 4	22	y_{18}	0.735 7
11	y_4	0.990 3	23	y_{33}	0.727 4
12	y_{14}	0.990 2	24	y_{19}	0.722 8

由表 6 可知,GSO 算法筛选后所得各负荷特征的评价指标 $\cos\varphi_k$ 均在 0.7 以上,说明优选得到的负荷特征与预测时刻负荷高度相关。对各负荷特征的评价指标进行排序,排序越靠前,则表示该负荷特征与预测时刻负荷相关度越强,为后文最优特征集确定作准备。

对于外部影响因素采用皮尔逊相关性分析方法。原始数据中包含日最高温度 x_1 、日最低温度 x_2 、日平均温度 x_3 、相对湿度 x_4 和降雨量 x_5 ,考虑日期类型 x_6 对不同负荷类型的影响,按照工作日记为 1、双休日或法定节假日记为 0 的原则统计数据。根据表 1,利用皮尔逊相关性分析剔除低相关的影响因素。不同负荷与单一影响因素的皮尔逊相关性分析如表 7 所示。由表 7 可知,日最高温度、日最低温度、日平均温度与负荷之间的皮尔逊相关系数 r 均超过 0.6,表明为强程度相关,且显著检验均为显著。日期类型与日最小负荷之间的 r 只有 0.2,但与日最大负荷和日平均负荷之间的 r 均超过 0.4,因此将日期类型与负荷视为中等程度相关。相对湿度和降雨量与负荷之间的 r 较小,且显著检验均为

不显著,由此说明在此数据集下,相对湿度和日降雨量与负荷的相关度不强,对负荷的影响几乎可以忽略,故外部影响因素最终选择日最高温度、日最低温度、日平均温度和日期类型。

表 7 不同负荷类型与单一影响因素的皮尔逊相关性分析
Table 7 Pearson correlation analysis of different loads and single meteorological factor

因素	日最大负荷		日最小负荷		日平均负荷	
	r	显著检验	r	显著检验	r	显著检验
x_1	0.600	显著	0.659	显著	0.601	显著
x_2	0.630	显著	0.720	显著	0.666	显著
x_3	0.608	显著	0.704	显著	0.646	显著
x_4	0.180	不显著	0.176	不显著	0.178	不显著
x_5	0.003	不显著	0.023	不显著	0.001	不显著
x_6	0.414	显著	0.200	不显著	0.401	显著

为了确定最优特征集 Z_m ,将 4 个相关度最强的外部影响因素和负荷特征组合的特征集分别输入到 ELM 模型中,采用交叉验证法,并根据 MAPE 确定最优特征集。 e_{MAPE} 越小,则代表该特征集对应的负荷预测精度越高。仿真结果显示,当特征维数少于 7 时, e_{MAPE} 会超过 1,由此表明选择合适特征维数对于预测十分关键。当特征维数大于等于 7 时,特征维数与 MAPE 的关系如图 5 所示。由图 5 可知:当特征维数 m 为 20 时, e_{MAPE} 最小;当特征维数 m 大于 20 时, e_{MAPE} 反而有所增加。由此说明特征维数为 20 时,ELM 模型预测效果能达到最佳,后加入的特征会给预测效果带来不利影响,因此将 20 个特征组成的最优特征集 Z_m 作为 ELM 的输入。




图 5 特征维数与 MAPE 的关系
Fig. 5 The relationship of feature dimension and MAPE

经 GSO-PCA 特征选择后的最优特征集见表 8。为验证 GSO-PCA 特征选择方法的优越性,与以往的特征选择方法进行对比,分别计算 MAPE。

表 8 最优特征集 Z_m
Table 8 The best feature set Z_m

外部影响 因素特征集	历史负荷特征集
x_1, x_2, x_3, x_6	$y_8, y_7, y_9, y_1, y_{10}, y_{11}, y_2, y_3, y_{12}, y_5, y_4,$ $y_{14}, y_{13}, y_6, y_{15}, y_{37}$

以往的特征选择方法主要分为经验特征选择法和机器学习特征选择法两类。在对比实验中:对于经验特征选择法,直接选用温度、预测日前 1~7 天同一时刻的负荷值作为最优特征集;对于机器学习特征选择法,选用最大互信息系数(MIC)和随机森林(RF)^[29]对特征进行优选。具体对比数据见表 9。

表 9 不同特征选择方法的误差对比
Table 9 Error comparison of different feature selection methods

特征选择方法	$e_{MAPE}/\%$
经验特征选择	5.43
MIC 特征选择	4.68
RF 特征选择	4.96
GSO-PCA 特征选择	4.13

由表 9 可知,本文提出的特征选择方法优于其他两类方法。与经验特征选择方法相比,能够较好地筛选出与预测时刻相关度高的特征;与单一的机器学习特征选择方法相比,能够更好地解决数据样本信息冗余、特征维数难以确定等问题。

5.3 实例分析与仿真实验对比

为了验证 IGWO-ELM 模型的优越性,本文在保证相同最优特征集条件下,选择不同算法优化的 ELM 模型进行对比实验,具体步骤如下。

步骤 1 确定训练集和测试集。将 2014 年 3 月 1 日—2014 年 3 月 14 日两周的负荷数据作为训练集,共 1 344 个样本。将 2014 年 3 月 15 日至 3 月 17 日 3 天的数据作为预测集,共 288 个样本。

步骤 2 确定输入量和输出量。利用 GSO-PCA 特征选择方法分别确定 3 个预测日的最优特征集,并以此为基础分别构建训练集和测试集,每个样本包括输入量和输出量,输入量由最优特征集组成,输出量为各个预测时刻的的负荷值。

步骤 3 对数据进行预处理。将样本数据统一归一

化至[0,1]。

步骤 4 设置 ELM 模型相关参数。以 MAPE 为评价指标,通过多次仿真可知,当隐含层节点数为 125 时 MAPE 最小,因此 ELM 隐含层节点数设置为 125,激活函数设置为 Sigmoid 函数。

步骤 5 得出结果并分析。将预处理后的样本数据分别输入不同的预测模型,得到预测结果并对结果进行误差分析。

本文的仿真实验平台为 Windows 10 操作系统、内存 16 GB 的计算机,运行环境为 Matlab 软件。为了保证所得结果的有效性和可靠性,算法的种群数量均取 30,最大迭代数均取 200。不同算法参数设置如下:GA 算法的交叉概率 p_c 为 0.7,变异概率 p_m 为 0.3;其余算法参数设置与 3.3 小节一致。

为了避免单次运行结果产生偏差,分别对不同预测模型独立运行 4 次,即 5 种预测模型共运行 20 次。对每种预测模型得到的 4 种负荷预测结果求和并取均值,得到各个不同预测模型的预测结果以及评价指标。表 10 为不同模型的预测精度对比,图 6 为不同模型的预测结果对比。

表 10 不同负荷预测模型精度对比
Table 10 Comparison of accuracy of different load forecasting model

预测模型	R^2	e_{MAE}/kW	e_{RMSE}/kW	$e_{MAPE}/\%$
ELM	0.961 4	322.34	283.22	4.89
GA-ELM	0.977 6	236.75	206.90	4.05
PSO-ELM	0.985 2	168.66	185.14	3.48
GWO-ELM	0.994 3	108.25	127.73	2.44
IGWO-ELM	0.997 8	54.90	72.02	1.52




图 6 不同负荷预测模型预测结果对比
Fig. 6 Comparison of results of different load forecasting model

由图6的局部放大图可知,本文预测模型所得的结果与真实值更加吻合。由表10可知:从拟合优度检验系数 R^2 分析,本文所提预测模型的 R^2 最接近1,拟合效果最好;从平均绝对误差分析,本文所提预测模型与ELM、GA-ELM、PSO-ELM以及GWO-ELM预测模型相比, e_{MAE} 分别下降了267.44、181.85、113.76和53.35 kW;从均方根误差分析,本文所提预测模型与其他传统预测模型相比, e_{RMSE} 分别下降了211.2、134.88、113.12和55.71 kW;从平均绝对百分比误差分析,本文所提预测模型与其他传统预测模型相比, e_{MAPE} 分别下降了3.37%、2.53%、1.96%和0.92%。综合可知,本文提出的IGWO算法优化ELM的预测模型具有更好的稳定性,负荷预测精度也有明显的提高。

6 结 论

本文提出了一种基于GSO-PCA特征选择和改进灰狼算法优化极限学习机的短期电力负荷预测方法,结合实际算例验证,得出结论如下。

(1)利用GSO-PCA对特征进行优选得到的最优特征集,既能表达负荷的有效信息,避免一些冗余信息的出现,也有利于ELM模型的学习与训练,同时降低了模型的复杂度,提高了负荷预测精度。

(2)IGWO算法克服了GWO算法易陷入局部最优解的缺点,与PSO、GWO等单一的算法相比具有更强的稳定性和寻优能力。

(3)利用IGWO算法对ELM的权值和阈值进行优化,获得了权值和阈值的全局最优解,从而能更好地解决ELM输出的不稳定问题。通过实例分析及对比实验可知,IGWO-ELM模型获得的4个评价指标均优于其他模型的,具有更好的预测精度和更强的泛化能力。

参考文献:

- [1] AURANGZEB K, ALHUSSEIN M, JAVAID K, et al. A pyramid-CNN based deep learning model for power load forecasting of similar-profile energy customers based on clustering [J]. IEEE Access, 2021, 9: 14992-15003.
- [2] 梁智,孙国强,李虎成,等.基于VMD与PSO优化深度信念网络的短期负荷预测[J].电网技术,2018,42(2):598-606.
LIANG Zhi, SUN Guoqiang, LI Hucheng, et al. Short-term load forecasting based on VMD and PSO optimized deep belief network [J]. Power System

Technology, 2018, 42(2): 598-606.

- [3] 牛东晓,曹树华,卢建昌.电力负荷预测技术及其应用[M].北京:中国电力出版社,2009:40-58.
- [4] 康重庆.电力系统负荷预测[M].北京:中国电力出版社,2017:32-41.
- [5] 陈昊.采用现代时间序列分析方法的电力负荷预测[M].北京:中国电力出版社,2007:2-3.
- [6] LU Shixiang, LIN Guoying, LIU Hanlin, et al. A weekly load data mining approach based on hidden Markov model [J]. IEEE Access, 2019, 7: 34609-34619.
- [7] 赵佩,代业明.基于实时电价和加权灰色关联投影的SVM电力负荷预测[J].电网技术,2020,44(4):1325-1332.
ZHAO Pei, DAI Yeming. Power load forecasting of SVM based on real-time price and weighted grey relational projection algorithm [J]. Power System Technology, 2020, 44(4): 1325-1332.
- [8] CHEN Kunjin, CHEN Kunlong, WANG Qin, et al. Short-term load forecasting with deep residual networks [J]. IEEE Transactions on Smart Grid, 2019, 10(4): 3943-3952.
- [9] RAFIEI M, NIKNAM T, AGHAEI J, et al. Probabilistic load forecasting using an improved wavelet neural network trained by generalized extreme learning machine [J]. IEEE Transactions on Smart Grid, 2018, 9(6): 6961-6971.
- [10] 廖旋焕,胡智宏,马莹莹,等.电力系统短期负荷预测方法综述[J].电力系统保护与控制,2011,39(1):147-152.
LIAO Nihuan, HU Zhihong, MA Yingying, et al. Review of the short-term load forecasting methods of electric power system [J]. Power System Protection and Control, 2011, 39(1): 147-152.
- [11] KAZEMI S M R, SEIED HOSEINI M M, ABBA-SIAN-NAGHNEH S, et al. An evolutionary-based adaptive neuro-fuzzy inference system for intelligent short-term load forecasting [J]. International Transactions in Operational Research, 2014, 21(2): 311-326.
- [12] 李文武,石强,李丹,等.基于VMD和PSO-SVR的短期电力负荷多阶段优化预测[J/OL].中国电力[2021-08-01].<http://kns.cnki.net/kcms/detail/11.3265.TM.20201221.1513.019.html>.
LI Wenwu, SHI Qiang, LI Dan, et al. Multi-stage optimization forecast of short-term power load based on VMD and PSO-SVR [J/OL]. Electric Power [2021-08-01]. <http://kns.cnki.net/kcms/detail/11.3265.TM.20201221.1513.019.html>.

- [13] LI Gen, LI Yunhua, ROOZITALAB F. Midterm load forecasting: a multistep approach based on phase space reconstruction and support vector machine [J]. IEEE Systems Journal, 2020, 14(4): 4967-4977.
- [14] 高琳, 高峰, 管晓宏, 等. 电力系统短期负荷预测的多神经网络 Boosting 集成模型 [J]. 西安交通大学学报, 2004, 38(10): 1026-1030.
- GAO Lin, GAO Feng, GUAN Xiaohong, et al. Neural networks ensemble model based on Boosting algorithm for short-term load forecasting [J]. Journal of Xi'an Jiaotong University, 2004, 38(10): 1026-1030.
- [15] GE Quanbo, JIANG Haoyu, HE Meiguang, et al. Power load forecast based on fuzzy BP neural networks with dynamical estimation of weights [J]. International Journal of Fuzzy Systems, 2020, 22(3): 956-969.
- [16] 程松, 闫建伟, 赵登福, 等. 短期负荷预测的集成改进极端学习机方法 [J]. 西安交通大学学报, 2009, 43(2): 106-110.
- CHENG Song, YAN Jianwei, ZHAO Dengfu, et al. Short-term load forecasting method based on ensemble improved extreme learning machine [J]. Journal of Xi'an Jiaotong University, 2009, 43(2): 106-110.
- [17] 董浩, 李明星, 张淑清, 等. 基于核主成分分析和极限学习机的短期电力负荷预测 [J]. 电子测量与仪器学报, 2018, 32(1): 188-193.
- DONG Hao, LI Mingxing, ZHANG Shuqing, et al. Short-term power load forecasting based on kernel principal component analysis and extreme learning machine [J]. Journal of Electronic Measurement and Instrumentation, 2018, 32(1): 188-193.
- [18] 张振中, 郭傅傲, 刘大明, 等. 基于最大互信息系数和小波分解的多模型集成短期负荷预测 [J]. 计算机应用与软件, 2021, 38(5): 82-87.
- ZHANG Zhenzhong, GUO Fuaao, LIU Daming, et al. Multi-model integrated short-term load prediction based on maximum mutual information coefficient and wavelet decomposition [J]. Computer Applications and Software, 2021, 38(5): 82-87.
- [19] 孔令春, 孙琼琼, 杨照峰. 蝙蝠算法优化极限学习机的电力负荷预测模型 [J]. 辽宁工程技术大学学报(自然科学版), 2016, 35(1): 89-92.
- KONG Lingchun, SUN Qiongqiong, YANG Zhao-feng. Load forecasting based on bat algorithm optimizing extreme learning machine [J]. Journal of Liaoning Technical University (Natural Science), 2016, 35(1): 89-92.
- [20] 律方成, 刘怡, 亓彦珣, 等. 基于改进遗传算法优化极限学习机的短期电力负荷预测 [J]. 华北电力大学学报(自然科学版), 2018, 45(6): 1-7.
- LÜ Fangcheng, LIU Yi, QI Yanyun, et al. Short-term load forecasting based on optimized learning machine using improved genetic algorithm [J]. Journal of North China Electric Power University (Natural Science Edition), 2018, 45(6): 1-7.
- [21] YANG Yi, SHANG Zhihao, CHEN Yao, et al. Multi-objective particle swarm optimization algorithm for multi-step electric load forecasting [J]. Energies, 2020, 13(3): 532.
- [22] 刘翊枫, 周国鹏, 刘昕, 等. 基于智能相似日识别及偏差校正的短期负荷预测方法 [J]. 电力系统保护与控制, 2019, 47(12): 138-145.
- LIU Yifeng, ZHOU Guopeng, LIU Xin, et al. A short-term load forecasting method based on intelligent similar day recognition and deviation correction [J]. Power System Protection and Control, 2019, 47(12): 138-145.
- [23] 孟凡煦. 基于变分模态分解和极限学习机的短期负荷预测方法研究 [D]. 大庆: 东北石油大学, 2019: 24-28.
- [24] MIRJALILI S, MIRJALILI S M, LEWIS A. Grey wolf optimizer [J]. Advances in Engineering Software, 2014, 69: 46-61.
- [25] 余今, 张德贤. 几种仿生优化算法综述 [J]. 软件导刊, 2019, 18(2): 49-51.
- YU Jin, ZHANG Dexian. Summaries on some novel bionic optimization algorithms [J]. Software Guide, 2019, 18(2): 49-51.
- [26] RAZA M Q, KHOSRAVI A. A review on artificial intelligence based load demand forecasting techniques for smart grid and buildings [J]. Renewable and Sustainable Energy Reviews, 2015, 50: 1352-1372.
- [27] LI Song, WANG Peng, GOEL L. A novel wavelet-based ensemble method for short-term load forecasting with hybrid neural networks and feature selection [J]. IEEE Transactions on Power Systems, 2016, 31(3): 1788-1798.
- [28] CHE Jinxing, WANG Jianzhou, TANG Yujuan. Optimal training subset in a support vector regression electric load forecasting model [J]. Applied Soft Computing, 2012, 12(5): 1523-1531.
- [29] 严雪颖, 秦川, 鞠平, 等. 负荷功率模型的最优特征选择研究 [J]. 电力工程技术, 2021, 40(3): 84-91.
- YAN Xueying, QIN Chuan, JU Ping, et al. Optimal feature selection of load power models [J]. Electric Power Engineering Technology, 2021, 40(3): 84-91.

(编辑 陶晴)