

基于改进 LS-SVM 的短期电力负荷预测方法研究

刘岩, 彭鑫霞, 郑思达

(国网冀北电力有限公司电力科学研究院, 北京 100045)

摘要: 针对电力负荷随机性强、稳定性差、预测精度不理想等问题, 提出了一种基于粒子群优化 PSO 和最小二乘支持向量机 LS-SVM 的短期负荷预测方法。模型的输入因子是负荷数据和气象信息等。粒子群优化算法用于实现支持向量机参数的自动优化, 建立了基于粒子群优化的最小二乘支持向量机短期负荷预测模型。通过仿真验证了改进前后预测模型的准确性和有效性。结果表明, 改进的预测方法具有收敛性好、预测精度高、训练速度快的优点。本研究为我国短期负荷预测方法的发展提供了参考和借鉴。

关键词: 电力负荷; 粒子群优化; 短期负荷; 最小二乘支持向量机; 预测模型

DOI: 10.19753/j.issn1001-4390.2021.05.026

中图分类号: TM734

文献标识码: A

文章编号: 1001-4390(2021)05-0176-06

Research on short-term power load forecasting method based on improved LS-SVM

Liu Yan, Peng Xinxia, Zheng Sida

(Electric Power Research Institute, State Grid Jibei Electric Power Co., Ltd., Beijing 100045, China)

Abstract: Aiming at the problems of strong randomness, poor stability and unsatisfactory forecasting accuracy of power load, a short-term power load forecasting method combining particle swarm optimization (PSO) and least squares support vector machine (LS-SVM) is proposed in this paper. The input factors of the model are load data and meteorological information. The particle swarm optimization algorithm is adopted to realize the automatic optimization of the parameter of the support vector machine, short-term load forecasting model of the least squares support vector machine based on particle swarm optimization is established. The accuracy and validity of the improved prediction model are verified by simulation, the results show that the improved prediction method brings benefits to convergence, prediction accuracy and training speed. This study provides a reference for the development of short-term load forecasting methods in China.

Keywords: power load, PSO, short-term load, LS-SVM, prediction model

0 引言

众所周知, 整个电力系统是一个瞬态系统, 发电、输电、配电和用电这四个过程同时形成动态平衡状态^[1]。精确地规划可确保瞬时电力系统始终高效、安全地运行。电力系统的快速发展已成为社会经济发展不可或缺的一部分, 电力系统负荷预测是电力系统稳定快速发展的重要基础^[2]。近年来, 许多研究表明, 准确的短期负荷预测对电力系统运行和经济发展有直接影响。不断提高其精度不仅可以确保电力系统的可靠运行, 而且还确保了对用户的持续供电^[3]。对短期负荷预测方法的研究具有重要的现实意义。

目前, 国内外学者对短期负荷预测方法进行了大量研究。随着研究的不断深入, 越来越多的研究朝着传统预测方法和优化方法结合或多种不同预测模型或方法的结合。文献[4]提出了一种基于一阶最小二乘法的多时间序列方程模型来预测负荷, 与非线性和非参数方法相比, 提高了负荷预测的准确性; 文献[5]通过小波分解模糊灰色聚类对天气因素进行聚类, 通过聚类天气因素来确定预测日的相似日类型。将相同类型的负载数据加载到神经网络中以进行负荷预测, 提高负荷预测的准确性; 文献[6]提出了一种基于负载聚类、RBF神经网络共轭梯度学习和相似加权综合的大用户负荷预测方法, 获得了良好的预测结果。这些研究为解决电力系统短期预测方法提供了理论依据。

基金项目: 国网总部科技项目(52010119000R)

基于上述研究,提出了一种结合粒子群优化 PSO (Particle Swarm Optimization) 和最小二乘支持向量机 LS-SVM(Least Squares Support Vector Machine) 的短期负荷预测方法。该模型以负荷数据和气象信息为输入因子,引入粒子群优化算法优化模型参数。通过仿真验证了改进预测模型的准确性和有效性。

1 系统框架

电力负荷预测系统具有负荷数据采集、数据分析和数据管理功能^[7]。结合云计算技术实现科学的电力负荷预测,为用户决策提供依据。电力负荷预测系统遵循标准化、可靠性、可用性、安全性、可扩展性和复杂性的原则^[8]。整个系统架构分为数据采集层、云数据中心和数据可视化层。系统的总体框架如图 1 所示。

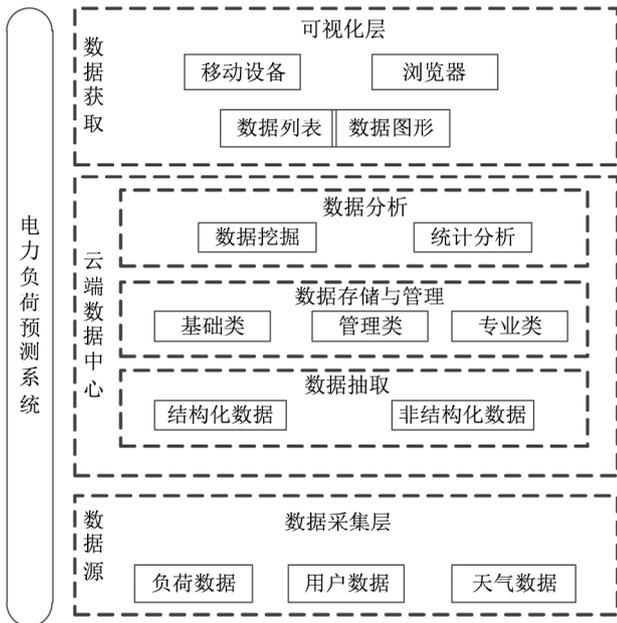


图 1 系统总体架构

Fig. 1 Overall architecture of system

2 预测模型

2.1 LS-SVM 预测模型

最小二乘支持向量机将最小二乘线性系统引入支持向量机,最小二乘支持向量机的优化指数采用平方项。采用等式约束用于替换标准支持向量机方法中的不等式约束,并把标准支持向量机中解的二次规划问题简化成求解线性方程问题。

设置一个培训样本 $\{x_k, y_k\}_{k=1}^N, k = 1, 2, \dots, N$ 。其中 $x_k \in \mathbf{R}^N$ 为输入向量; $y_k \in \mathbf{R}$ 为输出向量; 回归函数如式(1)所示^[9]:

$$f(x) = \omega \cdot \varphi(x) + b \quad (1)$$

式中 ω 为权重向量; b 为偏执值; $\varphi(x)$ 为输入空间到高维特征空间的非线性映射。LS-SVM 的优化目标如式(2)所示^[10]:

$$\begin{cases} \min J = (\omega, \rho) = \frac{1}{2} \|\omega\|^2 + \frac{1}{2} C \sum_{k=1}^N e_k^2 \\ \text{s. t. } y_k = \omega \varphi(x_k) + b + e_k, k = 1, 2, \dots, N \end{cases} \quad (2)$$

式中 e_k 为误差, $e \in \mathbf{R}^{N \times 1}$ 为误差向量; C 为控制误差的惩罚程度。通过引入拉格朗日乘数, $\lambda \in \mathbf{R}^{N \times 1}$, 带入式(2)得^[11]:

$$L(\omega, b, \rho, \alpha) = \frac{1}{2} \|\omega\|^2 + \frac{1}{2} C \sum_{k=1}^N e_k^2 - \sum_{k=1}^N \alpha_k (\omega \cdot \varphi(x_k) + b + e_k - y_k) \quad (3)$$

由 KKT 条件,如式(4)所示^[12]:

$$\begin{cases} \frac{\partial L}{\partial \omega} = 0 \rightarrow \omega = \sum_{k=1}^N \alpha_k \varphi(x_k) \\ \frac{\partial L}{\partial b} = 0 \rightarrow \sum_{k=1}^N \alpha_k = 0 \\ \frac{\partial L}{\partial e_k} = 0 \rightarrow \alpha_k = C e_k, k = 1, 2, \dots, N \\ \frac{\partial L}{\partial \alpha_k} = 0 \rightarrow \omega \varphi(x_k) + b + e_k - y_k, k = 1, 2, \dots, N \end{cases} \quad (4)$$

消去 ω 和 e , 则式(4)的解如式(5)所示^[13]:

$$\begin{bmatrix} 0 \\ \mathbf{Y} \end{bmatrix} = \begin{bmatrix} 0 & \mathbf{Q}^T \\ \mathbf{Q} & \mathbf{K} + C^{-1} \mathbf{I} \end{bmatrix} \begin{bmatrix} b \\ \alpha \end{bmatrix} \quad (5)$$

式中 $\alpha = [\alpha_1, \alpha_2, \dots, \alpha_N]^T$; $\mathbf{Q} = [1, 1, \dots, 1]^T$; $\mathbf{y} = [y_1, y_2, \dots, y_N]^T$; \mathbf{I} 为单位矩阵; \mathbf{K} 为核矩阵; C 为正则化参数; $K(x_k, x_k)$ 为选择合适的核函数,且 $K(x_k, x_k) = \varphi(x_k) \cdot \varphi(x_k)$, 并通过引入核函数简化计算。LS-SVM 预测模型如式(6)所示^[14]:

$$y = \sum_{k=1}^N \alpha_k K(x, x_k) + b \quad (6)$$

通过对式(5)进行求解,得到 α_k 和 b 。 $K(x, x_k)$ 为输入空间到高维特征空间的非线性映射。其中 $K(x, x_k)$ 为径向基核函数,如式(7)所示^[15]:

$$K(x, x_k) = \exp\left[-\frac{\|x - x_k\|^2}{2\sigma^2}\right] \quad (7)$$

式中 x 表示 m 维输入向量; x_k 为第 i 个径向基函数的中心; σ 为标准化参数; $\|x - x_k\|$ 为向量 $x - x_k$ 的范数。

在 LS-SVM 建模过程中,有必要确定两个参数 C 和 σ 。 C 值越小,偏差惩罚越小,支持向量机回归曲线

就越平稳,越有可能导致学习不足; C 值越高,偏差惩罚越大,大部分点都可以满足,可能导致过度学习。当 σ 很小,可能会发生局部优化,能够导致 SVM 产生过训练;如果 σ 很大,则很容易发生欠训练^[16]。

LS-SVM 建模的具体过程如图 2 所示。具体的建模步骤如下:

- 步骤一: 找到输入,纠正误差并将其标准化;
- 步骤二: 形成一天的训练样本;
- 步骤三: 对参数 C 和核参数 σ 进行确认;
- 步骤四: 计算 α_i 、 b 参数,建立 LS-SVM 预测模型;
- 步骤五: 预测一天的 24 h 负荷。

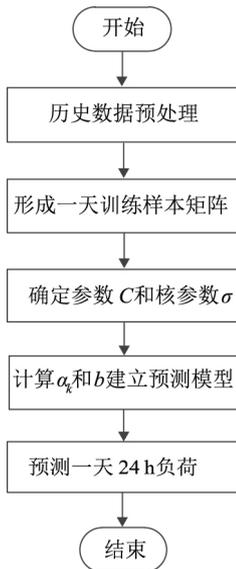


图 2 LS-SVM 建模流程图

Fig. 2 LS-SVM modeling flow chart

2.2 PSO 优化的 LS-SVM 模型

为了解决 LS-SVM 短期负荷预测中经验选择参数引起的大误差问题,运用粒子群算法对 LS-SVM 方法中核函数的参数进行优化,建立 PSO-LS-SVM 短期负荷预测模型。粒子群优化算法是一种基于群体智能的启发式算法,基本思想是在进化过程中,将“粒子”作为优化问题的解,其适应性决定了粒子的优越性,并使用目标函数来确定每个粒子的适应度^[17]。新粒子的位置由飞行速度 v 决定, v 的大小是根据种群进化过程的个体最优 $pbest_{id}$ 和全局最优 $gbest$ 计算。PSO 具体搜索过程如下:

$$V_{id}^{k+1} = \omega V_{id}^k + c_1 r_1 (pbest_{id} - x_{id}^k) + c_2 r_2 (gbest - x_{id}^k) \quad (8)$$

$$x_{id}^{k+1} = x_{id}^k + V_{id}^{k+1} \quad (9)$$

式中 $i = 1, 2, \dots, m$, m 为粒子数; $d = 1, 2, \dots, n$, n 为维数; c_1 和 c_2 为自学习系数和社会学习系数; r_1

和 r_2 为随机数,在 $[0, 1]$ 之间; x_{id}^k 和 V_{id}^k 为第 k 次迭代的位置和速度。

为了获得更好的预测结果,需要在构建预测模型之前设置以下参数:

- (1) 粒子群优化算法的搜索范围: $C \in [0.1, 150]$, $\sigma \in [0.1, 10]$ ^[18];
- (2) 粒子的数量: 选择 $m = 20$,以防止由于粒子的数量过多而导致全局优化^[19];
- (3) 惯性权重 ω : 适当 ω 值对于实现全局搜索和局部搜索都很重要。不仅减少迭代次数而且提高运行效率,最终找到最优解, $\omega \in [0.4, 0.9]$ ^[20];
- (4) 加速常数: 设置学习因子 c_1 和 c_2 ,以使粒子向组内最优个体进行学习,每次总结最后达到组内最优点。文中 $c_1 = c_2 = 2$ 。PSO-LS-SVM 模型流程图如图 3 所示,预测模型的实现步骤如下:

步骤一: 从历史数据中检索输入变量;
步骤二: 形成一天训练样本矩阵;
步骤三: 使用 PSO 算法初始化种群;
步骤四: 计算粒子的适应度,设置 $pbest_{id}$ 和 $gbest$,更新粒子的速度和位置,最后使用粒子群对种群进行优化;

步骤五: 满足条件返回到第四步,并重复以达到停止状态;

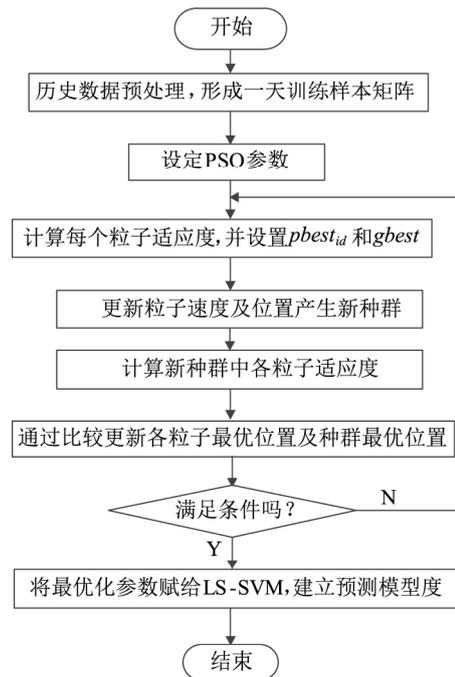


图 3 PSO-LS-SVM 模型流程图

Fig. 3 Flow chart of PSO-LS-SVM model

步骤六: 建立 PSO-LS-SVM 预测模型;
步骤七: 预测一天的 24 h 负荷。

3 仿真分析

3.1 仿真参数

为了更好地评估 PSO-LS-SVM 模型的预测性能。预测该地区各种日期类型(工作日 ,周末和十一节假日) 的负荷。从 2018 年 10 月起随机抽取 3 天 ,并与当地控制中心的实际数据与 LS-SVM 预测模型的预测结果进行比较。文中采集的数据主要包括历史负荷数据和气象信息等 ,选出可用数据。表 1 ~ 表 3 为所示预测结果的对比表 ,图 4 ~ 图 6 为相应预测对比曲线。

表 1 10 月 16 日预测模型预测值与实际值(工作日)

Tab. 1 Predicted and actual values of the prediction model on October 16 (working days)

预测模型	LS-SVM			PSO-LS-SVM	
	实际值 /MW	预测值 /MW	平均绝对误差 /%	预测值 /MW	平均绝对误差 /%
01:00	732.70	712.33	2.78	723.40	1.27
02:00	696.40	676.97	2.79	687.84	1.23
03:00	688.32	667.80	2.98	679.02	1.35
04:00	688.21	668.32	2.89	681.26	1.01
05:00	688.64	669.01	2.85	682.16	0.94
06:00	697.59	678.34	2.76	690.54	1.01
07:00	790.04	767.84	2.81	780.96	1.15
08:00	859.75	839.55	2.35	850.72	1.05
09:00	871.15	891.53	2.34	881.69	1.21
10:00	868.08	888.66	2.37	877.11	1.04
11:00	858.45	836.98	2.50	847.54	1.27
12:00	891.97	866.02	2.91	880.38	1.30
13:00	977.27	950.39	2.75	965.73	1.18
14:00	819.07	795.48	2.88	810.30	1.07
15:00	814.60	791.06	2.89	807.51	0.87
16:00	827.72	803.30	2.95	820.19	0.91
17:00	846.31	821.01	2.99	836.07	1.21
18:00	886.60	864.78	2.46	878.70	0.89
19:00	981.35	957.50	2.43	968.98	1.26
20:00	959.52	936.88	2.36	946.76	1.33
21:00	902.40	881.37	2.33	891.48	1.21
22:00	846.44	825.53	2.47	837.05	1.11
23:00	827.66	805.23	2.71	819.22	1.02
24:00	758.99	738.12	2.75	750.34	1.14

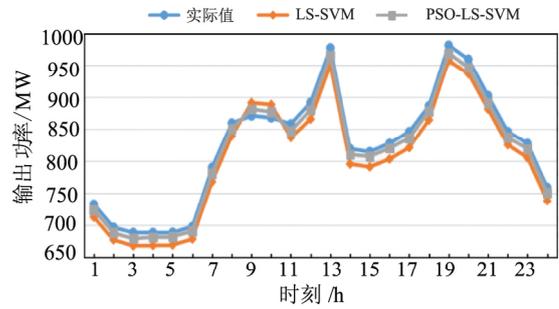


图 4 10 月 16 日预测对比曲线

Fig. 4 Forecasting contrast curve on October 16

表 2 10 月 14 日预测模型预测值与实际值(周日)

Tab. 2 Forecast and actual values of the forecast model on October 14 (Sunday)

预测模型	LS-SVM			PSO-LS-SVM	
	实际值 /MW	预测值 /MW	平均绝对误差 /%	预测值 /MW	平均绝对误差 /%
01:00	648.69	629.35	2.98	641.03	1.18
02:00	646.15	627.47	2.89	639.23	1.07
03:00	620.18	601.88	2.95	614.78	0.87
04:00	613.77	595.41	2.99	608.18	0.91
05:00	626.69	611.27	2.46	619.10	1.21
06:00	656.23	640.28	2.43	650.39	0.89
07:00	679.89	663.85	2.36	671.32	1.26
08:00	745.34	727.97	2.33	735.42	1.33
09:00	813.35	793.26	2.47	801.97	1.40
10:00	824.29	800.31	2.91	814.32	1.21
11:00	800.87	777.24	2.95	791.10	1.22
12:00	797.10	774.94	2.78	786.97	1.27
13:00	845.19	821.61	2.79	834.80	1.23
14:00	755.87	733.34	2.98	745.66	1.35
15:00	792.42	769.52	2.89	784.42	1.01
16:00	793.11	769.72	2.95	785.66	0.94
17:00	794.62	772.68	2.76	786.59	1.01
18:00	822.48	799.36	2.81	810.96	1.40
19:00	893.10	872.11	2.35	881.04	1.35
20:00	931.61	909.81	2.34	920.34	1.21
21:00	871.98	851.32	2.37	862.91	1.04
22:00	849.96	828.71	2.50	839.16	1.27
23:00	758.83	736.75	2.91	748.91	1.30
24:00	690.96	670.57	2.95	683.08	1.14

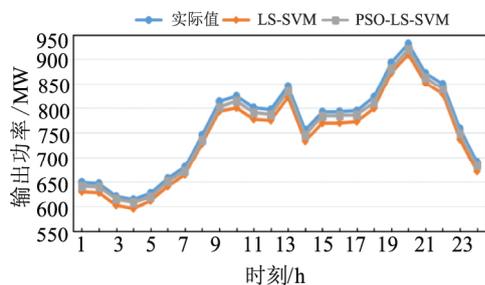


图 5 10 月 14 日预测对比曲线

Fig. 5 Forecast contrast curve on October 14

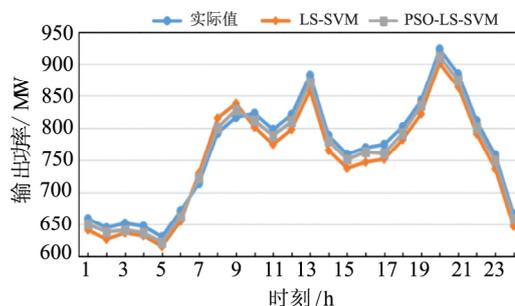


图 6 10 月 1 日预测对比曲线

Fig. 6 Forecast contrast curve on October 1

表 3 10 月 1 日预测模型预测值与实际值(特殊节假日)

Tab. 3 Predicted and actual values of the forecast model on October 1 (special holidays)

预测模型	LS-SVM			PSO-LS-SVM	
	实际值 /MW	预测值 /MW	平均绝对误差 /%	预测值 /MW	平均绝对误差 /%
01:00	659.38	641.18	2.76	650.48	1.35
02:00	644.69	626.57	2.81	638.17	1.01
03:00	651.94	636.62	2.35	641.25	1.64
04:00	647.24	632.09	2.34	636.94	1.59
05:00	630.31	615.37	2.37	621.49	1.40
06:00	671.81	655.01	2.50	662.74	1.35
07:00	714.23	730.37	2.26	722.87	1.21
08:00	792.62	815.69	2.91	800.87	1.04
09:00	817.23	838.40	2.59	828.43	1.37
10:00	822.91	801.76	2.57	812.21	1.30
11:00	797.97	775.14	2.86	788.87	1.14
12:00	821.05	798.22	2.78	810.62	1.27
13:00	882.70	858.07	2.79	871.84	1.23
14:00	788.89	765.38	2.98	780.37	1.08
15:00	759.49	737.54	2.89	751.36	1.07
16:00	769.78	747.07	2.95	763.08	0.87
17:00	775.00	751.82	2.99	760.97	1.81
18:00	802.25	782.51	2.46	792.54	1.21
19:00	842.99	822.50	2.43	835.48	0.89
20:00	923.01	901.22	2.36	911.38	1.26
21:00	884.81	864.20	2.33	874.81	1.13
22:00	811.60	791.55	2.47	801.45	1.25
23:00	758.75	736.67	2.91	749.57	1.21
24:00	666.67	647.00	2.95	659.87	1.02

比较图 4 ~ 图 6 ,可以看出 ,改进预测模型的负荷曲线比 LS-SVM 模型更接近实际负荷曲线。从表 4 的数据可以看出 ,LS-SVM 模型的平均绝对误差为 2.68% ,最大绝对误差为 2.71% ,最小绝对误差为 2.65% 。 PSO-LS-SVM 模型的平均绝对误差为 1.17% ,最大绝对误差为 1.24% ,最小绝对误差为 1.13% 。

表 4 改进前后日误差比较

Tab. 4 Comparisons of daily errors before and after improvement

日期	LS-SVM /%	PSO-LS-SVM /%
10 月 16 日	2.68	1.17
10 月 14 日	2.71	1.24
10 月 1 日	2.65	1.13
平均绝对误差	2.68	1.18

3.2 结果分析

根据上述仿真结果 ,运用粒子群优化和粒子群优化迭代的思想确定最优目标函数值 ,确定最优参数 ,并将其赋值给负荷预测模型进行负荷预测。 PSO-LS-SVM 模型平均绝对误差较 LS-SVM 模型的平均绝对误差低 1.5% 。结果表明经过 PSO 算法改进的 LS-SVM 模型提高了原模型的预测准确度以及效率。改进之后的预测模型具有良好的预测效果 ,用于电力系统短期负荷预测是有效和可行的。

4 结束语

短期负荷预测对于电力系统日常运行和优化调度至关重要 ,文章提出了一种基于粒子群优化 PSO 和最小二乘支持向量机 LS-SVM 的短期负荷预测方法。利用粒子群优化算法自动优化模型参数 ,建立 PSO-LS-SVM 短期负荷预测模型。通过实例验证了改进模型的正确性和有效性 ,结果表明 ,改进模型具有较高的预测精度和较好的预测效果。鉴于当前实验室设备和数据

规模,研究仍处于起步阶段,在此基础上,逐步改进和完善将成为下一步的重点。

参 考 文 献

[1] 姜冬,刘鲲鹏. 主动配电网双层实时优化博弈研究[J]. 电测与仪表, 2018, 55(18): 50-56.
Jiang Dong, Liu Kunpeng. Research on double-layer real-time optimization game of active distribution network[J]. Electrical Measurement & Instrumentation, 2018, 55(18): 50-56.

[2] 何忠华,张涛,胡嫫欧,等. 考虑大气污染防治措施影响的短期电力负荷预测模型研究[J]. 智慧电力, 2019, 47(5): 1-9.
He Zhonghua, Zhang Tao, Hu Yu'ou, et al. Short-term Electric Load Forecasting Model Considering the Influence of Air Pollution Prevention and Control Policy[J]. Smart Power, 2019, 47(5): 1-9.

[3] 贲驰,张晓华,马煜,等. 基于分时电价的电力负荷自动调度系统[J]. 电网与清洁能源, 2019, 35(7): 32-37.
Ben Chi, Zhang Xiaohua, Ma Yu, et al. Multi-Load Automatic Dispatching System Based on Time-of-Use Tariff[J]. Power System and Clean Energy, 2019, 35(7): 32-37.

[4] 孙毅,崔灿,张璐,等. 智能用电非侵入式负荷监测系统研究[J]. 电力科学与技术学报, 2019, 34(2): 155-160.
Sun Yi, Cui Can, Zhang Lu, et al. Research on nonintrusive load monitoring system for global energy internet[J]. Journal of Electric Power Science and Technology, 2019, 34(2): 155-160.

[5] 汪泉,周玮,王昊,等. 面向电力测试装置远程校准的网络服务质量可靠性建模与分析[J]. 高压电器, 2019, 55(6): 111-116.
Wang Quan, Zhou Wei, Wang Hao, et al. Modeling and Analysis of Network Service Quality Reliability for Power Meter Remote Calibration[J]. High Voltage Apparatus, 2019, 55(6): 111-116.

[6] 张志,杜延菱,崔慧军,等. 考虑关联因素的智能化中长期电力负荷预测方法[J]. 电力系统保护与控制, 2019, 47(2): 24-30.
Zhang Zhi, Du Yanling, Cui Huijun, et al. Intelligent mid-long electricity load forecast method considering associated factors[J]. Power System Protection and Control, 2019, 47(2): 24-30.

[7] 谷云东,马冬芬,程红超. 基于相似度改进梯度提升决策树的电力负荷预测[J]. 电力系统及其自动化学报, 2018, 41(23): 1234-1239.
Gu Yundong, Ma Dongfen, Cheng Hongchao. Power load forecasting based on improved gradient lifting decision tree[J]. Proceedings of the CSU-EPSA, 2018, 41(23): 1234-1239.

[8] 陶仁峰,李凤婷,李永东,等. 基于云层分布规律与太阳光跟踪的光伏电站 MPPT 策略[J]. 电力系统自动化, 2018, 29(5): 113-116.
Tao Renfeng, Li Fengting, Li Yongdong, et al. Photovoltaic power plant MPPT strategy based on cloud distribution law and solar tracking[J]. Power System Automation, 2018, 29(5): 113-116.

[9] 王电钢,黄林,刘捷,等. 考虑负荷虚假数据注入攻击的电力信息物理系统防御策略[J]. 电力系统保护与控制, 2019, 47(1): 28-34.
Wang Diangang, Huang Lin, Liu Jie, et al. Cyber-physical system defense strategy considering loaded false data injection attacks[J]. Power System Protection and Control, 2019, 47(1): 28-34.

[10] 王月林,李凤婷,王洪涛,等. 基于风电联络线恢复电压的自适应单相重合闸[J]. 电测与仪表, 2017, 41(7): 77-90.

[11] J. Nahman, D. Salamon. Mutual interference of neighboring grounding systems and approximate formulation[J]. Electric Power Systems Research, 2017, 41(12): 151-156.

[12] Vuyani Moses, Rowan Hatherley, Özlem Tastan Bishop. Bioinformatic characterization of type-specific sequence and structural features in auxiliary activity family 9 proteins[J]. Biotechnology for Biofuels, 2016, 9(1): 88-94.

[13] Kaiyuan Hou, Guanghui Shao, Haiming Wang, et al. Research on practical power system stability analysis algorithm based on modified SVM[J]. Protection and Control of Modern Power Systems, 2018, 3(2): 2-7.

[14] Garvishkumar K. Patel, Vipul K. Dabhi, Harshadkumar B. Prajapati. Clustering Using a Combination of Particle Swarm Optimization and K-means[J]. Journal of Intelligent Systems, 2017, 12(3): 457-469.

[15] Jyoti V. Gautam, Harshadkumar B. Prajapati, Vipul K. Dabhi, et al. Empirical Study of Job Scheduling Algorithms in Hadoop MapReduce[J]. Cybernetics and Information Technologies, 2017, 21(1): 146-163.

[16] C. E. F. Caetano, A. B. Lima, J. O. S. Paulino, et al. A conductor arrangement that overcomes the effective length issue in transmission line grounding[J]. Electric Power Systems Research, 2018, 46(5): 159-162.

[17] Jianjiang Hu, Maximilian Fichtner, Marcello Baricco. Preparation of Li-Mg-N-H hydrogen storage materials for an auxiliary power unit[J]. International Journal of Hydrogen Energy, 2017, 42(27): 17144-17148.

[18] Zhiwei Jia, L-Jun Wang, Ji-Chuan Zhang, et al. High Efficiency, Low Power-Consumption DFB Quantum Cascade Lasers Without Lateral Regrowth[J]. Nanoscale Research Letters, 2017, 12(1): 88-95.

[19] Caleigh M. Azumaya, Emily L. Days, Paige N. Vinson, et al. Screening for AMPA receptor auxiliary subunit specific modulators[J]. PLOS ONE, 2017, 12(3): 1523-1538.

[20] Fan Chengli. Hybrid artificial bee colony algorithm with variable neighborhood search and memory mechanism[J]. Journal of Systems Engineering and Electronics, 2018, 29(2): 405-414.

作者简介:



刘岩(1989—)男,工程师,硕士,从事电能计量和用电信息采集技术研究。Email: hancel@bjhzwq.com

彭鑫霞(1990—)女,助理工程师,硕士,从事电能计量相关技术研究。
郑思达(1990—)男,助理工程师,硕士,从事用电信息采集相关技术研究。

收稿日期: 2019-07-19; 修回日期: 2019-12-05
(任美辉 编发)