

DOI:10.3969/j.issn.2097-0706.2022.03.006

基于时间序列和BP神经网络的电能替代潜力 分析方法

Analysis method of electric energy substitution potential based on time series and
BP neural network

廖敏乐,黄重阳,戴承承,李化林,樊高松

LIAO Minle, HUANG Chongyang, DAI Chengcheng, LI Hualin, FAN Gaosong

(广西电网有限责任公司崇左供电局,广西 崇左 532200)

(Chongzuo Power Supply Bureau of Guangxi Power Grid Company Limited, Chongzuo 532200, China)

摘要:提出了基于时间序列和误差逆传播(Back Propagation, BP)神经网络的组合预测方法,利用基于三次指数平滑法的时间序列模型对电能替代量预测进行预测,对预测结果利用BP神经网络进行修正。利用国家统计局的能源使用情况作为数据进行预测和对比分析。算例结果表明,使用基于时间序列和BP神经网络的组合预测相比于单方法预测可以显著提高电能替代量的预测精度,可用于电能替代潜力分析。

关键词:电能替代潜力;时间序列;BP神经网络;组合预测

中图分类号:TK 01

文献标志码:A

文章编号:2097-0706(2022)03-0038-06

Abstract: A prediction method based on time series and BP neural network is proposed. The time series model based on cubic exponential smoothing method is used to predict the electric energy substitution, and the prediction results are corrected by BP neural network. The prediction and comparative analysis on energy consumption are made according to the data from National Bureau of Statistics. The results of a case study show that the combination forecast method based on time series and BP neural network can make a more accurate prediction on electric energy substitution than a single prediction method, which provides certain guidance for the analysis on electric energy substitution potential.

Keywords: electric energy substitution potential; time series forecast; BP neural network; combination forecast

0 引言

2020年9月,我国提出2030年前实现碳达峰、2060年前实现碳中和目标^[1]。而清洁替代与电能替代作为实现的重要途径逐渐受到关注^[2-5]。

近年来,国内外专家学者针对电能替代潜力的评估和预测2方面进行了研究。在电能替代潜力的评估方面,文献[3]建立了基于电能替代弹性特征的最优电能替代负荷模型,提出了电能替代边界的量化评估方法,对主要国家和地区的电能替代趋势进行了预判。文献[6]从经济社会发展水平、终端能源消费结构、能源价格等7个方面构建了区域电能替代潜力评估指标体系,对区域电能替代潜力进行评估。文献[7]从社会经济水平、能源消费结构、环保约束、经济性、配套支持5个方面构建了中国区

域电能替代潜力评估指标体系来科学的评估电能替代潜力,使用联系度优化的优劣解距离法(Technique for Order Preference by Similarity to an Ideal Solution, TOPSIS)对各区域的电能替代潜力进行评估,提出了相应的电能替代推广策略。在电能替代潜力的预测方面,文献[8]建立了关于电能替代的环境负荷模型,分情景实现了对终端电能替代量的有效预测。文献[9-10]提出了基于粒子群优化支持向量机的电能替代潜力分析方法,通过支持向量机实现影响因素与累计电能替代量的拟合分析。文献[11]基于Logistic模型分别对终端能源消费总量和电能占终端能源消费比例进行了预测。

目前电能替代潜力研究存在的问题,一是电能替代潜力的预测方面研究较少;二是电能替代预测多是由单个预测方法分析得到的结果,组合预测在电能替代潜力分析中并不常见。时间序列能够结合历史数据在短期预测上表现优异^[12],误差逆传播

收稿日期:2021-09-17;修回日期:2021-10-12

基金项目:南方电网有限公司科技项目(GXKJXM20180201)

(Back Propagation, BP)神经网络具有自学习和自适应能力强的优点^[13],这2种预测方法在电力系统领域的相关组合预测方面已有较好应用。文献[14]结合改进的集合经验模式分解和长时短期记忆,并通过改进的入侵杂草优化算法对碳价格进行了预测。文献[15-16]引入混沌时间序列理论和粗糙集理论改进 Elman 神经网络并进行建模,对短期用电量进行了预测,取得了良好的效果。文献[17]提出了一种基于信息融合策略的BP,小波变换和相关向量机组合预测模型对短期风电进行预测。文献[18]建立了自回归滑动平均模型和遗传算法优化的BP神经网络组合模型,对东北电网大停电事故进行综合分析预测。文献[19-20]通过灰色理论和BP神经网络模型对短期电力负荷进行预测。文献[21]提出了2种动态神经网络预测模型对风电场输出功率进行了预测,预测方法适应风功率的时间序列特性,预测精度较高。

在此基础上,考虑到时间序列在短期预测的优势以及神经网络能够弥补时间序列受历史数据影响大以及中长期预测精度低的缺点,提出一种基于时间序列和神经网络的组合预测方法,对电能替代潜力进行分析。利用国家统计局的历史数据,进行预测和分析,验证组合预测方法的有效性,为电能替代的推广提供参考。

1 电能替代潜力的量化分析

设第 t 年实际电能使用量为 $C_e(t)$,能源总使用量为 $C(t)$,假设在短时间内终端能源使用格局不变。定义第 $t+1$ 年电能替代量为当年电能使用量占能源总使用量与上一年电能使用量占能源总使用量之差与当年能源总使用量的乘积,即

$$D_e(t+1) = \left(\frac{C_e(t+1)}{C(t+1)} - \frac{C_e(t)}{C(t)} \right) \times C(t+1) = C_e(t+1) - C(t+1) \frac{C_e(t)}{C(t)}, \quad (1)$$

式中: $D_e(t+1)$, $C_e(t+1)$, $C(t+1)$ 分别为第 $t+1$ 年的电能替代量、实际电能使用量及能源使用总量, TW·h。

2 基于时间序列和BP神经网络的电能替代预测

2.1 基于三次指数平滑法的时间序列预测模型

利用时间序列预测电能替代量的流程如图1所示。为验证时间预测方法的可行性,需要对电能替代量的数据列作必要的检验处理。由于受环境影响,有的年份电能替代量为负值,而终端电能使用量占能源总使用量的比例同电能替代量有相同的

变化趋势,且两者的差别只在于电能替代量为2年终端电能占比的差值乘以能源总使用量。终端电能使用量占比以及与能源替代量的关系为

$$\begin{cases} E_c^{(0)}(t) = \frac{C_e(t)}{C(t)} \\ D_e(t+1) = (E_c^{(0)}(t+1) - E_c^{(0)}(t)) \times C(t+1) \end{cases}, \quad (2)$$

式中: $E_c^{(0)}(t)$ 为第 t 年终端电能使用量占比,%; $C_e(t)$, $C(t)$ 分别为第 t 年实际电能使用量及能源总使用量, TW·h; $D_e(t+1)$ 为第 $t+1$ 年的电能替代量, TW·h。




图1 时间序列预测流程

Fig. 1 Flowchart for time series prediction

采用终端电能使用量占比进行预测,设终端电能使用量占比的数据列为 $E_c^{(0)} = (E_c^{(0)}(1), E_c^{(0)}(2), \dots, E_c^{(0)}(n))$ 。计算序列的级比为

$$\lambda(k) = \frac{E_c^{(0)}(k-1)}{E_c^{(0)}(k)}, k = 2, 3, \dots, n. \quad (3)$$

如果所有的级比 $\lambda(k)$ 都落在可容覆盖 $\Theta = (e^{-2/n+1}, e^{2/n+1})$ 内,则终端电能使用量占比序列可以作为时间预测模型的数据进行预测。

在电能替代量的预测序列满足条件后,可根据式(4)生成二次型的累加序列

$$E_c^{(1)} = (E_c^{(1)}(1), E_c^{(1)}(2), \dots, E_c^{(1)}(n)) = [(E_c^{(0)}(1), E_c^{(0)}(1) + E_c^{(0)}(2), \dots, E_c^{(0)}(1) + \dots + E_c^{(0)}(n))]. \quad (4)$$

生成累加序列后,可基于三次指数平滑法的时间序列计算参数值,三次指数平滑法计算公式为

$$\begin{cases} S_k^{(1)} = \alpha E_c^{(1)}(k) + (1-\alpha)S_{k-1}^{(1)} \\ S_k^{(2)} = \alpha S_k^{(1)} + (1-\alpha)S_{k-1}^{(2)} \\ S_k^{(3)} = \alpha S_k^{(2)} + (1-\alpha)S_{k-1}^{(3)} \end{cases}, \quad (5)$$

式中: $S_k^{(1)}$, $S_k^{(2)}$, $S_k^{(3)}$ 分别为一次指数平滑值、二次指数平滑值和三次指数平滑值。对于 α 值的选取,若选取 $\alpha=0$,后一阶段的预测值就等于本阶段的预测值,在预测过程中不考虑任何新信息;若选取 $\alpha=1.0$,后一阶段的期预测值就等于本阶段的观测值,完全不相信过去的信息。根据这2种极端情况很难做出正确的预测,因此 α 值应根据时间序列的具体性质在

0~1.0 选择。选择 α 可遵循 2 条原则: 如果时间序列较为平稳, 则 α 的值应取不超过 0.5 以减少修正幅度, 使得预测模型能考虑到较长时间序列的信息; 如果时间序列具有明显的波动, 则 α 的值应取较大值 (如 0.6~0.8), 提高预测模型灵敏度, 以便迅速跟上数据的变化。累加序列的预测值公式为

$$E_C^{(1)}(k+m) = a_k + b_k m + c_k m^2, \quad (6)$$

式中:

$$\begin{cases} a_k = 3S_k^{(1)} - 3S_k^{(2)} + S_k^{(3)} \\ b_k = \frac{\alpha}{2(1-\alpha)^2} [(6-5\alpha)S_k^{(1)} - 2(5-4\alpha)S_k^{(2)} + (4-3\alpha)S_k^{(3)}] \\ c_k = \frac{\alpha^2}{2(1-\alpha)^2} [S_k^{(1)} - 2S_k^{(2)} + S_k^{(3)}] \end{cases} \quad (7)$$

得到累加序列的预测值后, 按照下式进行还原, 得到实际电能替代量的预测值。

$$\begin{aligned} E_C^{(0)}(k+m) &= E_C^{(1)}(k+m) - E_C^{(1)}(m), \\ k &= 1, 2, \dots, n-1, n. \end{aligned} \quad (8)$$

2.2 改进的 BP 神经网络算法

BP 神经网络具有学习速度慢、容易陷入局部最优解以及网络层数、神经元个数的选择没有相应的理论指导等缺点。而变动量因子可以加速算法收敛速度, 变学习率可以避免落入局部最优解。其训练过程如图 2 所示。




图 2 神经网络训练过程

Fig. 2 Flowchart for the training process of neural network

采用变动量因子和变学习率的 BP 算法可以加快网络的学习速度, 减少神经元个数选择对网络预

测精度的影响。其步骤如下。

(1) 初始化权值 v_{ik}, w_{kj} 和阈值 $\theta_k, \theta_j (i=1, 2, \dots, d; k=1, 2, \dots, q; j=1, 2, \dots, l; d, q, l$ 分别为输入层、输出层、隐藏层的神经元个数)。给权值和阈值设置在 $[-1, 1]$ 范围内的初值, 将原始数据初始化。

(2) 选择一组 2.1 节中时间预测结果, 设为 $x_i (i=1, 2, \dots, d)$ 以及对应的终端电能使用量占比实际值 $y_j (j=1, 2, \dots, l)$ 。

(3) 计算 BP 神经网络实际输出 $\hat{y}_j$ 。

1) 计算隐藏层输出

$$b_k = f\left(\sum_{i=1}^d v_{ik} x_i - \theta_k\right), k = 1, 2, \dots, q, \quad (9)$$

式中: $f(x)$ 为隐藏层的激活函数, 取

$$f(x) = \frac{1}{1 + e^{-x}}. \quad (10)$$

2) 计算输出层输出

$$\hat{y}_j = f\left(\sum_{k=1}^q w_{kj} b_k - \theta_j\right), j = 1, 2, \dots, l. \quad (11)$$

(4) 修正权值

$$w_{kj}(t+1) = w_{kj}(t) + \eta(t) \delta_j(t) b_k + \alpha(t) [w_{kj}(t) - w_{kj}(t-1)], \quad (12)$$

$$v_{ik}(t+1) = v_{ik}(t) + \eta(t) \delta_k(t) x_i + \alpha(t) [v_{ik}(t) - v_{ik}(t-1)], \quad (13)$$

式中: $\eta(t)$ 为变学习率; φ 为神经网络 2 次学习之间误差超曲面的夹角; ω 为比例系数, $0.1 < \omega < 0.2$; $w_{kj}(t) - w_{kj}(t-1)$ 及 $v_{ik}(t) - v_{ik}(t-1)$ 为动量项; $\alpha(t)$ 为变动量因子。其中

$$\eta(t) = e^{\omega \cos \varphi} \times \eta(t-1), \quad (14)$$

$$\alpha(t) = \frac{\delta_j^2(t)}{\sum_{m=1}^{t-1} \delta_j^2(t)}, \quad (15)$$

$$\delta_j(t) = (\hat{y}_{ij} - y_{ij}) y_{ij} (1 - y_{ij}), \quad (16)$$

$$\delta_k(t) = b_k (1 - b_k) \delta_{kj}(t) w_{kj}, \quad (17)$$

(5) 如果误差达到精度或者最大循环次数, 则输出结果, 否则转步骤 (2)。

2.3 基于时间序列和 BP 神经网络组合预测

基于时间序列在短期预测的优势以及 BP 神经网络能够弥补时间序列受历史数据影响大的特点, 将时间序列和 BP 神经网络进行组合预测, 模型的精度是由时间序列与 BP 神经网络的精度共同决定的。时间序列的精度取决于参数 α 的取值, BP 神经网络的精度取决于训练出的网络参数。理论上, 采用神经网络对预测数据进行修正原理上可提升预测效果, 减小预测误差, 具体流程如图 3 所示。

(1) 将 m 种不同序列长度的终端电能使用量占比采用时间序列模型进行预测, 得到在同一年份 t

的预测结果分别为 $x_{i1}, x_{i2}, \cdots, x_{in}$ 。

(2)使用终端电能使用量的历史数据训练神经网络模型,得到固定的权重与阈值。

(3)将步骤(1)的结果作为训练好的神经网络模型的输入,经过神经网络模型得到输出预测值。




图 3 基于时间序列和BP神经网络训练的预测结果流程

Fig. 3 Flowchart of prediction results based on time series and BP neural network training

3 实例分析

为验证提出的时间序列和BP神经网络组合预测方法预测电能替代量的可行性,以我国2000—2019年能源使用量、电能使用量作为原始数据,计算出电能使用占比并根据电能替代潜力的量化公式计算出电能替代量作为参考,见表1。

利用基于三次平滑指数法的时间序列模型进行预测,2013—2019年的预测结果如图4所示。

分别计算每年的相对误差,结果见表2。由表2可见,在2013—2019年预测值的相对误差中,最小的偏离11.90%,而最大偏离44.59%。仅仅依靠时间序列模型进行预测在某些年份的偏差较大,这是因为基于三次指数平滑法的预测结果受加权系数 α 影响,不同的加权系数会造成预测结果的不同,选取不适当的加权系数会对结果产生较大影响,使得预测结果不具有可信度。

为此,改变时间序列的加权系数 α 的值,进行多次预测。对每年形成一组预测序列,2003—2010年的数据作为训练集,2011—2012年的数据作为验证集对BP神经网络进行训练。将表中2013—2019年的预测结果输入训练好的BP神经网络进行修正。为了比较基于神经序列和BP神经网络与其他方法的预测结果,选择基于马尔科夫链的预测模型进行预测,不同预测方法的结果如图5所示。由图5可见,仅采用时间序列进行预测的结果波动较大,偏

表 1 相关能源及电能使用参数				
Table 1 Parameters of electricity and its consumption				
年份	标准煤使用量/万 t	电能使用量/(TW·h)	电能使用量占能源使用量比例/%	电能替代量/(TW·h)
2000	146 964	1 347.238	11.266 40	84.902
2001	155 547	1 472.346	11.633 22	46.427
2002	169 577	1 646.545	11.933 24	41.397
2003	197 083	1 903.160	11.868 01	-10.461
2004	230 281	2 197.137	11.726 03	-26.604
2005	261 369	2 494.032	11.727 35	0.281
2006	286 467	2 858.797	12.264 80	125.275
2007	311 442	3 271.181	12.908 60	163.146
2008	320 611	3 454.135	13.240 76	86.649
2009	336 126	3 703.214	13.540 31	81.927
2010	360 648	4 193.449	14.290 25	220.068
2011	387 043	4 700.088	14.924 46	199.730
2012	402 138	4 976.264	15.208 28	92.869
2013	416 913	5 420.341	15.978 39	261.244
2014	425 806	5 638.369	16.273 97	102.409
2015	429 905	5 801.997	16.586 58	109.351
2016	435 819	6 129.709	17.285 64	247.897
2017	448 529	6 482.097	17.761 39	173.624
2018	464 000	7 033.075	18.628 55	327.393
2019	486 000	7 649.563	19.344 27	283.023




图 4 时间序列预测结果与实际结果对比

Fig. 4 Comparison between results of time series prediction and actual results

表 2 时间序列预测结果及相对误差			
Table 2 Results and relative errors of time series prediction method			
年份	真实值/(TW·h)	预测值/(TW·h)	相对误差/%
2013	261.243	292.339	11.90
2014	102.408	73.703	28.03
2015	109.350	60.589	44.59
2016	247.896	287.563	16.00
2017	173.622	193.463	11.42
2018	327.394	399.448	22.01
2019	283.023	329.835	16.54

离真实值的程度也是最大的。相比于单独采用时间序预测,采用马尔科夫链进行预测虽然也有波

动,但总体波动情况要好于时间序列预测。在采用基于时间序列和BP神经网络的组合预测后,最终的神经网络修正值离真实曲线更近,波动程度更小。这是因为利用了神经网络自学习的功能,不断根据输出偏差来更新权值以减小误差,弥补了时间序列受历史数据影响大并且模型受加权系数影响的缺点,使得最终的结果在精度上有了进一步提升。




图5 几种预测模型预测结果对比

Fig. 5 Comparison among prediction results of various prediction models

为了量化分析几种算法的优劣性,计算各算法的拟合程度。定义算法的 R^2 为

$$R^2 = \frac{(N \sum_{n=1}^N \hat{y}_n y_n - \sum_{n=1}^N y_n \sum_{n=1}^N y_n)^2}{\left[N \sum_{n=1}^N \hat{y}_n^2 - \left(\sum_{n=1}^N \hat{y}_n \right)^2 \right] \left[N \sum_{n=1}^N y_n^2 - \left(\sum_{n=1}^N y_n \right)^2 \right]}, \quad (18)$$

式中: N 为样本个数; $\hat{y}_n$ 为第 n 个电能替代量的预测值; y_n 为第 n 个电能替代量的真实值。计算结果见表3。

表3 不同预测模型的拟合程度

Table 3 Fitting precision of different forecasting models

预测模型	时间序列	马尔科夫链	时间序列+BP神经网络
R^2	0.706 3	0.336 7	0.962 8

由表3可见,单独时间序列预测的拟合程度为0.706 3,而单独使用马尔科夫链预测的拟合程度仅为0.300 0~0.400 0。提出的时间序列和BP神经网络的组合预测拟合程度相比于单独使用时间序列提高约0.300 0,达到了3种算法中最高的0.962 8。这说明时间序列和BP神经网络的组合预测在拟合程度上远远优于单个方法进行的预测,同时拟合值非常接近1.000 0也说明预测精度较高。BP神经网络在优化时间序列预测方法的缺点上完成度较高,从而提升了模型的预测精度。

综上所述,提出的时间序列和BP神经网络的组合预测方法用于电能替代量的预测,分析电能替代潜力上具有一定的优势,能够为后续电能替代的政策实施提供量化参考。

4 结论

首先将电能替代潜力进行量化,利用电能替代量进行表征。其次在分析时间序列预测优缺点的基础上建立了基于三次平滑指数法的时间序列与神经网络的组合预测模型,实现对电能替代量的短期预测。利用国家统计局的相关数据进行验证。算例表明,基于时间序列和BP神经网络的组合预测方法,相比于单个的预测方法,如时间序列预测、马尔科夫链预测等能够大大提高预测精度。在拟合程度上也优于单个预测模型,组合预测能将拟合程度提高约30%。精确的电能替代量预测能够为政策的制定以及短期规划提供量化依据,能够推动电能替代战略精确实施。

参考文献:

- [1]杨博文.习近平新发展理念下碳达峰、碳中和目标战略实现的系统思维、经济理路与科学路径[J].经济学家,2021(9):5-12.
YANG Bowen. The systematic thinking, economic logic and scientific path for the realization of carbon summit and carbon neutral target strategy under Xi Jinping's new development concept [J]. Economist, 2021(9):5-12.
- [2]刘振亚.电能替代是实现碳达峰碳中和的重要途径[J].记者观察,2021(13):41-45.
- [3]孙伟卿,谈一鸣,曾平良,等.考虑电能替代的全球负荷变化趋势分析[J].电网技术,2019,43(2):678-687.
SUN Weiqing, TAN Yiming, ZENG Pingliang, et al. Analysis on variation trend of global load considering electricity substitution [J]. Power System Technology, 2019, 43(2):678-687.
- [4]国家能源局.关于推进电能替代的指导意见[Z].发改能源[2016]1054号.2016.
- [5]刘可真,王骞,赵明,等.基于多方合作博弈及梯级化的电能替代效益分析[J].电网技术,2020,44(2):711-718.
LIU Kezhen, WANG Qian, ZHAO Min, et al. Benefit analysis of electric energy substitution based on multi-player cooperative game and cascade model [J]. Power System Technology, 2020, 44(2):711-718.
- [6]陈增.区域电能替代潜力评估体系及模型研究[D].北京:华北电力大学,2019.
- [7]李艳梅,陈增.基于联系度优化TOPSIS法的区域电能替代潜力评估研究[J].电网技术,2019,43(2):687-695.
LI Yanmei, CHEN Zeng. Study on regional electric energy substitution potential evaluation based on TOPSIS method of optimized connection degree [J]. Power System Technology, 2019, 43(2):687-695.
- [8]孙毅,周爽,单葆国,等.多情景下的电能替代潜力分析[J].电网技术,2017,41(1):118-123.

- SUN Yi, ZHOU Shuang, SHAN Baoguo, et al. Analysis of electric power alternative potential under multi-scenario [J]. Power System Technology, 2017, 41(1): 118-123.
- [9] 孙毅, 石墨, 单葆国, 等. 基于粒子群优化支持向量机的电能替代潜力分析方法[J]. 电网技术, 2017, 41(6): 1767-1771.
- SUN Yi, SHI Mo, SHAN Baoguo, et al. Electric energy substitution potential analysis method based on particle swarm optimization support vector machine [J]. Electric Power System Technology, 2017, 41(6): 1767-1771.
- [10] 陈涛, 吕松, 任廷林, 等. 基于最小二乘支持向量机的周用电量预测方法[J]. 华电技术, 2020, 42(1): 35-40.
- CHEN Tao, LYU Song, REN Tinglin, et al. Prediction method for weekly electricity consumption based on LSSVM algorithm [J]. Huadian Technology, 2020, 42(1): 35-40.
- [11] 刘国静, 谈健, 李琥, 等. 基于 Logistic 模型的电能替代电量预测[J]. 电力工程技术, 2018, 37(6): 39-43.
- LIU Guojing, TAN Jian, LI Hu, et al. Forecast of electric energy substitution based on logistic model [J]. Power System Technology, 2018, 37(6): 39-43.
- [12] WAGENA M B, GOERING D, COLLICK A S, et al. Comparison of short-term streamflow forecasting using stochastic time series, neural networks, process-based, and Bayesian models [J/OL]. Environmental Modelling and Software, 2020. (2020-04-08) [2021-10-09]. <https://doi.org/10.1016/j.envsoft.2020.104669>.
- [13] WU Y Q, GAO R L, YANG J Z. Prediction of coal and gas outburst: A method based on the BP neural network optimized by GASA [J]. Process Safety and Environmental Protection, 2020(133): 64-72.
- [14] YANG S M, CHEN D J, LI S L, et al. Carbon price forecasting based on modified ensemble empirical mode decomposition and long short-term memory optimized by improved whale optimization algorithm [J/OL]. Science of the Total Environment, 2020. (2020-05-10) [2021-10-09]. <https://doi.org/10.1016/j.scitotenv.2020.137117>.
- [15] 吴佳懋, 李艳, 符一健. 基于粗糙集-混沌时间序列 Elman 神经网络的短期用电量预测[J]. 电力系统保护与控制, 2019, 47(3): 23-30.
- WU Jiamao, LI Yan, FU Yijian. Short-term power consumption prediction based on rough set chaotic time series Elman neural network [J]. Power System Protection and Control, 2019, 47(3): 23-30.
- [16] 胡倩, 孙志达, 江珂滕, 等. 基于短期负荷打捆预测的售电公司偏差考核控制方法[J]. 华电技术, 2021, 43(4): 47-55.
- HU Qian, SUN Zhida, JIANG Keteng, et al. Deviation assessment and control method for electricity sales companies based on short-term load bundling forecast [J]. Huadian Technology, 2021, 43(4): 47-55.
- [17] ZHANG J H, MENG H, GU B, et al. Research on short-term wind power combined forecasting and its Gaussian could uncertainty to support the integration of renewables and EVs [J]. Renewable Energy, 2020(153): 884-899.
- [18] 于群, 张铮, 屈玉清, 等. 基于 ARMA-GABP 组合模型的电网大停电事故损失负荷预测[J]. 中国电力, 2018, 51(11): 38-44.
- YU Qun, ZHANG Zheng, QU Yuqing, et al. Power loss prediction of large blackouts in power grid based on ARMA-GABP combined model [J]. Electric Power, 2018, 51(11): 38-44.
- [19] 王瑞, 周晨曦, 逯静. 基于一种组合模型的短期电力负荷预测[J]. 计算机仿真, 2018, 35(12): 396-400.
- WANG Rui, ZHOU Chenxi, LU Jing. Short-term load prediction based on a combination model [J]. Computer Simulation, 2018, 35(12): 396-400.
- [20] 彭维珂, 聂椿明, 陈衡, 等. 基于智能算法的空冷火电机组负荷预测研究[J]. 华电技术, 2021, 43(3): 57-64.
- PENG Weike, NIE Chunming, CHEN Heng, et al. Study on load forecasting for air cooling thermal power units based on intelligent algorithm [J]. Huadian Technology, 2021, 43(3): 57-64.
- [21] 刘瑞叶, 黄磊. 基于动态神经网络的风电场输出功率预测[J]. 电力系统自动化, 2012, 36(11): 19-22, 37.
- LIU Ruiye, HUANG Lei. Wind power forecasting based on dynamic neural networks [J]. Automation of Electric Power Systems, 2012, 36(11): 19-22, 37.

(本文责编: 惠忻)

作者简介:

廖敏乐(1986), 男, 工程师, 从事电力电子及需求侧管理方面的研究, li_ml.czg@gx.csg.cn;

黄重阳(1980), 男, 工程师, 从事增量配电网及综合能源发展方面的研究, huang_cy.czg@gx.csg.cn;

戴承承(1986), 男, 工程师, 从事电网规划、并网管理及综合能源发展方面的研究, dai_cheng_cheng@126.com;

李化林(1977), 男, 工程师, 从事增量配电网需求侧管理、电网规划及综合能源规划方面的研究, li_hl.czg@gx.csg.cn;

樊高松(1985), 男, 高级工程师, 从事市场营销管理、增量配电网及综合能源发展方面的研究, fan_gs.czg@gx.csg.cn。