

基于联合模型的短期电力负荷预测方法

蔡君懿,李琪林,严平

(国网四川省电力公司计量中心,四川 成都 610045)

摘要:为了准确预测电力负荷并提高电力系统调节和调度的灵活性、准确性,提出了基于差分自回归滑动平均和长短期记忆神经网络的短期负荷联合模型预测方法,以避免单一预测模型可能难以满足预测准确需求的情况。首先,使用差分自回归滑动平均和长短期记忆神经网络单一模型对短期电力负荷开展预测;然后,使用改进的粒子群优化算法对联合模型权重进行寻优;最后,利用最优权重将单一模型预测结果进行合并得到最终的预测结果。验证结果表明,所建立的联合模型能够对短期电力负荷进行准确的预测,且联合模型的预测精度要优于差分自回归滑动平均、长短期记忆神经网络和BP神经网络等单一模型,具有一定的工程应用价值。

关键词:短期电力负荷预测;差分自回归滑动平均模型;长短期记忆神经网络;联合模型;混合粒子群算法

中图分类号:TM 715 **文献标志码:**A **文章编号:**1003-6954(2023)05-0027-08

DOI:10.16527/j.issn.1003-6954.20230505

Short-term Load Forecasting Method Based on Combined Model

CAI Junyi, LI Qilin, YAN Ping

(State Grid Sichuan Metering Center, Chengdu 610045, Sichuan, China)

Abstract: In order to accurately forecast power load and improve the flexibility and accuracy of power system regulation and scheduling, a short-term load forecasting method based on combined model of auto-regressive integrated moving average (ARIMA) and long short-term memory (LSTM) neural network is proposed to avoid that a single prediction model may be difficult to meet the prediction accuracy requirement. Firstly, the two single models of ARIMA and LSTM are used to forecast the short-term load, and then the hybrid particle swarm optimization (PSO) algorithm is used to optimize the weight of combined model. Finally, the forecasting results of the single model are combined with the optimal weight to obtain the final forecasting result. The verification results show that the proposed combined model can accurately forecast the short-term load, and its forecasting accuracy is better than that of single models of ARIMA, LSTM and back propagation neural network (BPNN), which has certain engineering application value.

Key words: short-term load forecasting; auto-regressive integrated moving average; long short-term memory neural network; combined model; hybrid particle swarm optimization

0 引言

随着以新能源作为主要供给的新型电力系统不断发展,为确保多元化新能源的高效消纳利用并发挥主体电源的电力支撑作用,需提升电力系统灵活调节能力。准确的电力负荷预测可以在保障电网的

安全前提下,经济合理地安排电网内部发电机组的启停、安排机组检修计划,为电力系统灵活调节、供需平衡提供基础。因此,电力负荷预测对于整个电力系统的运营决策和控制至关重要^[1]。根据时间尺度划分,电力负荷预测一般包括3种:1)中长期负荷预测(以年度为单位给出预测结果);2)短期负荷预测(从次日到第8天的预测);3)超短期负荷预测(15 min以下的电力负荷预测)^[2]。其中,短期负荷预期是电力系统运行和控制所需的,所受关注最高。

基金项目:国家电网有限公司总部科技项目“新型电力系统电磁测量设备及系统标准体系建设与国际化战略研究”(5700-20225225A-1-1-ZN)

短期负荷预测技术主要有统计学方法和机器学习方法两类^[3]。统计学方法包括自回归滑动平均(auto-regressive moving average, ARMA)^[4]、差分自回归滑动平均(auto-regressive integrated moving average, ARIMA)^[5]、卡尔曼滤波^[6]、多元线性回归(multiple linear regression, MLR)^[7]等算法。由于基于时间序列的实际电力负荷数据存在非线性与非平稳,若单独采用统计学方法进行负荷预测,则可能会对其非线性部分或非平稳部分预测造成缺失。为了改善此情况,基于机器学习的负荷预测方法得到了发展与应用。其中,支持向量机^[8-9]、神经网络^[10-11]以及它们的拓展算法^[12-15]是最常见的用于短期负荷预测的机器学习算法。为了优化机器学习的效果,学者们使用了一些结合方法来提高预测精度,如:使用注意力机制、引入门控循环单元和时间认知分别对神经网络进行优化^[16-18];基于小波去噪强化神经网络来提升短期负荷预测需求^[19];使用变分模态分解负荷时间序列再进行支持向量机预测^[20];使用主成分分析法对负荷序列进行降维处理,提升聚类效果^[21]等。总的来说,机器学习算法的非线性拟合能力较强,其短期负荷预测准确度普遍优于统计学方法^[3]。

由于电力系统中负荷数量多且短期负荷特征受天气、时间等诸多因素的影响,单一预测模型可能难以满足预测的准确性要求。因此提出了一种预测短期电力负荷的联合模型方法,该方法基于 ARIMA 模型和长短期记忆(long short-term memory, LSTM)神经网络模型的集成,以考虑两种技术的优势来提升预测精度。首先,描述了 ARIMA 和 LSTM 基础模型;然后,提出了基于混合粒子群优化算法的联合模型;最后,通过实际负荷数据对比、分析来验证所提方法。

1 基础模型

1.1 差分自回归滑动平均模型

不同于自回归滑动平均(ARMA)模型只能处理平稳序列,差分自回归滑动平均(ARIMA)模型是一种可用于非平稳时间序列的模型。ARIMA 模型最为关键的 3 个参数是自回归阶次 n 、差分阶次 d 以及滑动平均阶次 m ,因此一般表示为 ARIMA(n, d, m),是 ARMA(n, m)模型的扩展。

对于一个非平稳的时间序列 x ,对第 T 个元素进行一阶差分的公式为

$$\nabla x_T = x_T - x_{T-1} = (1 - B)x_T \quad (1)$$

式中, B 为延迟算子。

d 阶差分后的时间序列 y 为

$$y_T = \nabla^d x_T = (1 - B)^d x_T \quad (2)$$

在 ARIMA(n, d, m)模型中,若差分阶次 d 为 0,则 ARIMA($n, 0, m$)就变为 ARMA(n, m)模型。因此,非平稳时间序列经过若干次的差分后会变得平稳化,从而可构建相应的 ARMA 模型。ARMA(n, m)的第 T 个元素如式(3)所示^[22]。

$$z_T = \sum_{l=1}^n \varphi_l y_{T-l} + \sum_{j=1}^m \theta_j \varepsilon_{T-j} + \varepsilon_T \quad (3)$$

式中: ε_T 为服从均值为 0 正态分布的白噪声序列 ε 的第 T 个元素; φ_l 为第 l 个自回归系数; θ_j 为第 j 个移动平均系数。

在实际运用时,由于 1 阶差分之后信号通常可变得平稳,因此差分阶次 d 可取 1。当信号平稳以后,对信号进行偏自相关计算,根据偏自相关函数的截断项确定自回归阶次 n ;对信号进行自相关计算,根据自相关函数的截断项确定滑动平均阶次 m 。

1.2 长短期记忆神经网络模型

长短期记忆(LSTM)神经网络模型的核心思想是通过加入遗忘门、输入门和输出门组成的高效结构,使传统循环神经网络具备了学习长期信息的能力,从而解决了传统循环神经网络存在的梯度消失或梯度爆炸的问题^[23],其细胞结构如图 1 所示。




图 1 LSTM 细胞结构

3 个逻辑门中的主要功能^[24]分别为:

1) 遗忘门:决定保留或删除 $t-1$ 刻输出 h_{t-1} 的信息,并将输入门处理后得到的状态信息与当前处理结果相加,生成更新后的记忆单元状态。 $\sigma(\)$ 为 sigmoid 函数,用于在 0~1 之间产生一个权值,其

表达式为

$$\sigma(x_{in}) = \frac{1}{1 + e^{-x_{in}}} \quad (4)$$

式中, x_{in} 为函数输入。

在遗忘门中 t 时刻的输出为

$$f_t = \sigma[W_f(h_{t-1}, x_{in,t}) + b_f] \quad (5)$$

式中: $x_{in,t}$ 为 t 时刻的网络输入; W_f, b_f 分别为遗忘门 sigmoid 函数的权值和偏置。

2) 输入门: 通过调整新信息的权重, 从而更新细胞状态。输入门 sigmoid 函数 t 时刻的输出为

$$i_t = \sigma[W_i(h_{t-1}, x_{in,t}) + b_i] \quad (6)$$

式中, W_i 和 b_i 分别为输入门 sigmoid 函数的权值和偏置。

tanh 函数的作用是将值归一化到 $-1 \sim 1$ 之间, 其表达式为

$$\tanh x_{in} = \frac{e^{x_{in}} - e^{-x_{in}}}{e^{x_{in}} + e^{-x_{in}}} \quad (7)$$

输入门 tanh 函数 t 时刻的输出为

$$\tilde{C}_t = \tanh[W_c(h_{t-1}, x_{in,t}) + b_c] \quad (8)$$

式中, W_c 和 b_c 分别为输入门 tanh 函数的权值和偏置。利用遗忘门和输入门的输出即可对细胞 t 时刻的状态 C_t 进行更新, 如式(9)所示。

$$C_t = f_t C_{t-1} + i_t \tilde{C}_t \quad (9)$$

3) 输出门: 控制 LSTM 记忆模块的输出, 其依赖于上一个记忆单元的输出和当前遗忘门的状态。输出门 sigmoid 函数 t 时刻的输出为

$$O_t = \sigma[W_o(h_{t-1}, x_{in,t}) + b_o] \quad (10)$$

式中, W_o 和 b_o 分别为输出门 sigmoid 函数的权值和偏置。

该 LSTM 细胞结构的最终输出为

$$h_t = O_t \tanh C_t \quad (11)$$

LSTM 模型用于预测分析时, 可有两种方式:

1) 每次预测时, 使用前一次预测结果作为函数的输入, 即使用预测值进行预测; 2) 对新序列进行预测时进行网络状态重置, 即使用观测值进行预测。

LSTM 算法最关键的参数为隐藏层神经元数量和学习率。由于 LSTM 模型中的 3 个门是全连接层, 在算法执行的过程中, 会存在用隐藏层来做矩阵相乘运算。通常, 细胞数量和各隐藏层神经元数量相同, 若隐藏层神经元太少将导致欠拟合, 而隐藏层神经元太多可能会导致过拟合并增加训

练时间。隐藏层神经元数量一般根据问题的复杂度和可用的计算资源进行经验调节确定。学习率是对 LSTM 模型进行调整的幅度。学习率越大, 模型更新的幅度也越大, 模型的训练速度也会提高使模型不稳定, 甚至无法收敛; 学习率过小则会使模型训练速度缓慢, 也会导致无法收敛。一般而言, 初始学习率可以设置为较小的值, 然后如果模型的损失函数下降缓慢, 则可以适当增大学习率; 如果模型的损失函数出现不稳定或震荡, 则可以适当减小学习率。

2 基于混合粒子群算法的联合预测方法

2.1 基于混合粒子群算法的预测模型

在模型训练中, 若 ARIMA 模型得到的负荷序列为 \mathbf{a} 、LSTM 模型得到的负荷序列为 \mathbf{b} 、相应的实际负荷序列为 \mathbf{s} , 各有 n 个采样点。对 LSTM 模型负荷序列和 ARIMA 负荷序列分别赋予权重 ω_1 和 ω_2 , 且 $\omega_1 + \omega_2 = 1$, 则训练过程中联合预测模型的误差为

$$\varepsilon = \mathbf{s} - \omega_1 \mathbf{a} - \omega_2 \mathbf{b} = \mathbf{s} - \omega_1 \mathbf{b} - (1 - \omega_1) \mathbf{b} \quad (12)$$

以联合预测模型误差最小化作为优化目标求解权重, 得到

$$\omega_1^* = \arg \min |\varepsilon| = \arg \min [|\mathbf{s} - \omega_1 \mathbf{b} - (1 - \omega_1) \mathbf{b}|] \quad (13)$$

为寻求最优联合模型权重, 通过随机优化搜索算法进行寻找。设置目标函数为

$$g(\omega_1) = \sqrt{\sum_{i=1}^n [s_i - \omega_1 a_i - (1 - \omega_1) b_i]^2} \quad (14)$$

设置权重搜索范围为

$$0 \leq \omega_1 \leq 1 \quad (15)$$

粒子群优化算法 (particle swarm optimization, PSO) 是目前常用的随机搜索算法, 具有参数少、收敛快等优点, 其迭代公式^[25]为:

$$v_q(k+1) = Wv_q(k) + c_1 \text{rand}(0,1)[p_{q\text{best}}(k) - p_q(k)] + c_2 \text{rand}(0,1)[p_{g\text{best}}(k) - p_q(k)] \quad (16)$$

$$x_q(k+1) = x_q(k) + v_q(k+1) \quad (17)$$

式中: v_q 和 x_q 分别为第 q 个个体的速度和位置; $\text{rand}(0,1)$ 为 $0 \sim 1$ 之间的随机数; k 为迭代次数;

p_{qbest} 为第 q 个粒子的最佳位置; p_{gbest} 为所有个体的最佳位置; c_1 和 c_2 为学习因子; W 为惯性权重。

由于粒子群优化算法的种群多样性易损失, 导致其易发生早期收敛性。为此, 使用混合粒子群优化算法增加收敛精度, 该混合粒子群优化算法使用差分进化 (differential evolution, DE) 算法的变异、交叉操作来提高粒子群优化算法的种群多样性, 从而提高搜索准确度。变异操作是基于 3 个随机个体 A_{r_1} 、 A_{r_2} 、 A_{r_3} 进行的, 第 q 个个体的第 k 次迭代表达式^[26]为

$$V_q(k) = A_{r_1}(k) + F \times (A_{r_2}(k) - A_{r_3}(k)) \quad (18)$$

式中, F 为缩放因子。

交叉操作是将有 N 维分量的第 q 个个体的第 u 分量进行交叉, 其规则为

$$R_q^u(k) = \begin{cases} V_q^u(k), & \text{rand}(0,1) \leq C \text{ 或 } j = \text{rand}(1,N) \\ A_q^u(k), & \text{其他} \end{cases} \quad (19)$$

式中, C 为交叉率, 其值在 0~1 之间。

通过寻找式 (19) 的最小值, 即可得到最优联合模型权重。

2.2 联合模型预测方法

联合模型预测方法的流程如图 2 所示。首先, 分别使用 ARIMA 模型和 LSTM 模型得到单一模型的预测结果; 然后, 基于混合粒子群算法求出最优的联合模型权重, 从而对单一模型预测结果进行合成, 得到联合模型的预测结果。

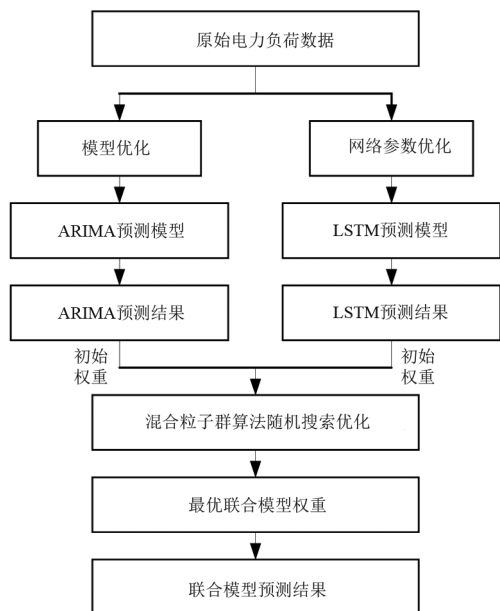


图 2 联合模型预测方法流程

3 应用验证

3.1 原始负荷数据

选用某地 2014 年 12 月份 31 天的负荷数据作为案例进行分析验证^[27]。负荷数据每小时检测一次, 一天共有 24 个数据, 波形曲线如图 3 所示。




图 3 案例负荷数据波形

利用最大谱峰搜索对负荷数据序列进行周期分解^[28], 得到周期分量和剩余非周期分量如图 4 所示。可以看出其中周期分量幅值较小, 所占比例较少, 大部分为非周期分量。因此无法直接判断下一周期内的电力负荷, 须使用预测模型与算法进行预测。




图 4 案例负荷数据周期分量

为分析不同预测模型的实际效果, 分别利用前 10 天、前 20 天和前 30 天的数据预测第 11 天、第 21

天和第 31 天的负荷序列,此 3 天的日内负荷曲线如图 5 所示。




图 5 第 11 天、第 21 天和第 31 天负荷曲线


3.2 ARIMA 模型预测结果

负荷数据自相关与偏自相关在 6 阶时系数为 0 或接近于 0,且后续阶数基本落在 2 倍标准差范围,如图 6 所示,所以 n 与 m 皆取 6,从而建立模型 ARIMA(6, 1, 6)。根据模型参数进行程序编制,输入进行训练的负荷数据,得到使用 ARIMA 模型预测不同日期的电力负荷序列结果如图 7 所示。从图中可以看出 ARIMA 模型能够对电力负荷趋势进行一定的预测,但是幅值上存在明显的偏移,最大的预测误差绝对值达到了 287 MW,这是由于原始负荷数据中存在较多的非周期成分,导致 ARIMA 模型的适用性下降造成的。


3.3 LSTM 模型预测结果

通过调节,确定所使用的 LSTM 模型的隐藏层神经元数量为 200,学习率为 0.005。使用 LSTM 模型预测不同日期的电力负荷序列结果如图 8 所示。可以看出 LSTM 模型均能对电力负荷进行一定的预测,其中有重置网络的 LSTM 模型预测结果相较于无重置网络的 LSTM 模型预测结果更贴近于实际曲线。无重置网络的 LSTM 模型预测结果的最大预测误差绝对值为 503 MW,而有重置网络的 LSTM 模型预测结果的最大预测误差绝对值仅为 159 MW。进一步均以均方根误差 (root mean square error, RMSE) 作为预测评价指标,表达式为

$$E_{\text{RMS}} = \sqrt{\frac{1}{M} \sum_{l=1}^M (\hat{y}_l - y_l)^2} \quad (20)$$



(a) 自相关



(b) 偏自相关

图 6 负荷数据自相关与偏自相关分析

式中: M 为预测序列的数据点数量; \hat{y}_l 为第 l 个预测值; y_l 为第 l 个实际值。


有无重置网络 LSTM 模型预测性能对比结果如表 1 所示。结果显示,有重置网络的 LSTM 模型的预测结果 RMSE 比无重置网络的 LSTM 模型的预测结果 RMSE 至少减少了 50.73%,这表明当 LSTM 模型随预测结果进行重置网络后可以大幅有效地提升预测结果性能,这是因为重置网络状态可防止先前的预测影响对新数据的预测。因此,后续使用有重置网络的 LSTM 模型进行联合模型预测。

表 1 有无重置网络 LSTM 模型预测性能对比


预测日期	预测结果 RMSE/MW	
	无重置	有重置
第 11 天	96.63	34.56
第 21 天	150.78	61.46
第 31 天	93.16	45.87

3.4 联合模型预测结果


使用混合粒子群算法,以第 11 天 ARIMA 模型和有重置网络的 LSTM 模型预测结果进行联合模型权重系数寻优,得到 $\omega_1 = 0.9081$, $\omega_2 = 0.0919$ 。进



(a) 第11天



(b) 第21天



(c) 第31天


图 7 ARIMA 模型预测结果

一步得到第 11 天、第 21 天、第 31 天的联合模型预测结果,如图 9 所示。可以看出联合模型的预测结果与实际曲线非常接近,各日期下预测误差均较小。


3.5 对比分析

除了所使用的 ARIMA 和 LSTM 这两种单一模型以外,还将常用于预测分析的 BP 神经网络(back propagation neural network, BPNN)^[28]与联合模型的结果进行对比,如图 10 所示。图 10 显示 ARIMA 模型的预测曲线与真实曲线的偏差较大,而 LSTM 模型、BPNN 模型和联合模型的预测曲线与真实曲线较为相似。


单一模型与联合模型预测性能对比如表 2 所示。从表中可以看出,LSTM 模型和 BPNN 模型的



(a) 第11天



(b) 第21天




(c) 第31天

图 8 LSTM 模型预测结果


预测效果优于 ARIMA 模型预测效果,这是因此负荷序列存在非平稳、非线性部分,机器学习方法更为适用;而联合模型相较于单一模型取得了更好的预测精度,这是因为联合模型可以消除单一模型在不同方向上的误差,从而提升预测性能。综上所述,ARIMA-LSTM 联合模型的预测精度最优,可以较准确地对短期电力负荷进行预测。

表 2 单一模型与联合模型预测性能对比


预测日期	预测结果 RMSE/MW			
	ARIMA 模型	LSTM 模型	BPNN 模型	联合模型
第 11 天	131.73	34.56	44.27	32.05
第 21 天	95.03	61.46	68.36	58.59
第 31 天	132.68	45.87	45.55	42.79



(a) 第11天



(b) 第21天



(c) 第31天

图 9 联合模型预测结果


4 结 论

为进一步提高短期电力负荷预测的准确度,上面提出了基于 ARIMA 和 LSTM 的联合模型,实现对电力系统短期负荷进行精准预测。实验验证结果表明:


1)混合粒子群算法可以准确计算出联合模型中各单一模型的最优权重,实现基于 ARIMA 和 LSTM 单一模型的联合优化;

2)相较于单一预测模型,ARIMA-LSTM 联合模型可以消除单一模型在不同方向上的误差,使短期电力负荷预测精度提升,具有较高的工程实用价值。


所提方法为多种负荷预测算法的联合使用提供了一种思路,除所使用的 ARIMA 和 LSTM 算法以



(a) 第11天



(b) 第21天



(c) 第31天

图 10 单一模型与联合模型预测结果对比

外,所提出的算法联合使用计算方法,也望应用于其他算法来提高短期电力负荷预测精度。

参考文献

[1] RAFI S H, NAHID-AL-MASOOD, DEEBA S R, et al. A short-term load forecasting method using integrated CNN and LSTM network [J]. IEEE Access, 2021, 9: 32436-32448.

[2] 全国电网运行与控制标准化技术委员会. GB/T 31464—2022 电网运行准则[S].北京:中国标准出版社, 2022.

[3] 钟光耀, 邵能灵, 黄文焘, 等. 基于多维聚类的配变负荷注意力短期预测方法 [J]. 上海交通大学学报, 2021, 55(12): 1532-1543.

[4] 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.

- [5] 麦鸿坤,肖坚红,吴熙辰,等.基于 R 语言的负荷预测 ARIMA 模型并行化研究[J].电网技术,2015,39(11):3216-3220.
- [6] 刘鑫,滕欢,宫毓斌,等.基于改进卡尔曼滤波算法的短期负荷预测[J].电测与仪表,2019,56(3):42-46.
- [7] 邓带雨,李坚,张真源,等.基于 EEMD-GRU-MLR 的短期电力负荷预测[J].电网技术,2020,44(2):593-602.
- [8] 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.
- [9] 杨邓,杨俊杰,胡晨阳,等.基于改进 LSSVM 的短期电力负荷预测[J].电子测量技术,2021,44(18):47-53.
- [10] 马松龄,代一楠,徐军昶,等.改进人工蜂群优化神经网络的短期负荷预测[J].机械设计与制造,2021(7):50-53.
- [11] 蔡秋娜,潮铸,苏炳洪,等.基于一种新型鲁棒损失的神经网络短期负荷预测方法[J].电网技术,2020,44(11):4132-4139.
- [12] 吕海灿,王伟峰,赵兵,等.基于 Wide&Deep-LSTM 模型的短期台区负荷预测[J].电网技术,2020,44(2):428-436.
- [13] 朱凌建,荀子涵,王裕鑫,等.基于 CNN-Bi LSTM 的短期电力负荷预测[J].电网技术,2021,45(11):4532-4539.
- [14] 王保义,王冬阳,张少敏.基于 Spark 和 IPPSO_LSSVM 的短期分布式电力负荷预测算法[J].电力自动化设备,2016,36(1):117-122.
- [15] 陈纬楠,胡志坚,岳菁鹏,等.基于长短期记忆网络和 LightGBM 组合模型的短期负荷预测[J].电力系统自动化,2021,45(4):91-97.
- [16] 赵兵,王增平,纪维佳,等.基于注意力机制的 CNN-GRU 短期电力负荷预测方法[J].电网技术,2019,43(12):4370-4376.
- [17] 王增平,赵兵,纪维佳,等.基于 GRU-NN 模型的短期负荷预测方法[J].电力系统自动化,2019,43(5):53-58.
- [18] DENG Z F, WANG B B, XU Y L, et al. Multi-scale convolutional neural network with time-cognition for multi-step short-term load forecasting[J]. IEEE Access, 2019, 7:88058-88071.
- [19] EKONOMOU L, CHRISTODOULOU C A, MLADENOV V. A Short-term load forecasting method using artificial neural networks and wavelet analysis [J]. International Journal of Power Systems, 2016, 1:64-68.
- [20] 赵凤展,郝帅,张宇,等.基于变分模态分解-BA-LSSVM 算法的配电网短期负荷预测[J].农业工程学报,2019,35(14):190-197.
- [21] MOORE B. Principal component analysis in linear systems: control lability, observability, and model reduction[J]. IEEE Transactions on Automatic Control, 1981, 26(1):17-32.
- [22] AKAIKE H. Power spectrum estimation through autoregressive model fitting[J]. Annals of the Institute of Statistical Mathematics, 1969, 21:407-419.
- [23] 陈振宇,刘金波,李晨,等.基于 LSTM 与 XGBoost 组合模型的超短期电力负荷预测[J].电网技术,2020,44(2):614-620.
- [24] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computation, 1997, 9(8):1735-1780.
- [25] KENNEDY J, EBERHART R C. Particle swarm optimization [C]. Proceedings of IEEE International Conference on Neural Networks, 1995, 4:1942-1948.
- [26] STORN R, PRICE K. Differential evolution-A simple and efficient heuristic for global optimization over continuous spaces [J]. Journal of Global Optimization, 1997, 11:341-359.
- [27] HONG T, PINSON P, FAN S, et al. Probabilistic energy forecasting: global energy forecasting competition 2014 and beyond [J]. International Journal of Forecasting, 2016, 32(3):896-913.
- [28] LI Q L, CAI J Y, YAN P, et al. A short-term load forecasting method based on fast periodic component extraction [C]. 2022 5th International Conference on Pattern Recognition and Artificial Intelligence (PRAI), Chengdu, China, 2022:875-879.
- [29] CHEN Y X, ZHANG J Y, LIU Y S, et al. Research on the prediction method of ultimate bearing capacity of PBL based on IAGA-BPNN algorithm[J]. IEEE Access, 2020, 8:179141-179155.

作者简介:

蔡君懿(1996),女,博士,工程师,从事电能计量与电气设备检测工作;

李琪林(1973),男,博士,教授级高级工程师,从事电能计量工作;

严平(1966),男,硕士,高级工程师,从事电能计量工作。

(收稿日期:2023-03-01)