

# 基于马尔科夫残差修正-自回归滑动平均模型的负荷预测

惠杰<sup>1</sup> 刘博嘉<sup>1</sup> 赵树生<sup>1</sup> 胡金丹<sup>1</sup> 曾先锋<sup>2</sup>

(1. 常州博瑞电力自动化设备有限公司, 江苏 常州 213025;

2. 南京南瑞继保电气有限公司, 南京 211102)

**摘要** 为提高中短期负荷预测的准确度, 本文提出基于马尔科夫残差修正的自回归滑动平均模型。采用自回归滑动平均模型进行用电负荷预测和残差计算, 利用马尔科夫残差修正算法对预测结果进行修正。工程案例表明, 自回归滑动平均模型的负荷预测误差绝对值均值为13.67%, 经马尔科夫残差修正后的负荷预测误差绝对值均值为6.912%, 预测准确度提升了49.4%, 证明本文所提中短期负荷预测模型可以用于指导工业用户中短期生产调度等。

**关键词:** 负荷预测; 马尔科夫修正; 自回归滑动平均; 中短期特性

## Load forecasting based on Markov residual correction-autoregressive moving average model

HUI Jie<sup>1</sup> LIU Bojia<sup>1</sup> ZHAO Shusheng<sup>1</sup> HU Quidan<sup>1</sup> ZENG Xianfeng<sup>2</sup>

(1. Changzhou Boil Electric Power Automation Equipments Co., Ltd, Changzhou, Jiangsu 213025;

2. NR Electric Co., Ltd, Nanjing 211102)

**Abstract** To improve the forecasting accuracy of short and medium term loads, this article proposes an autoregressive moving average model based on Markov residual correction. The autoregressive moving average model is used to predict the load and calculate the residual, and the Markov residual correction algorithm is used to correct the prediction results. The engineering case verification shows that the average absolute error of load forecasting obtained by the autoregressive moving average model is 13.67%. After Markov residual correction, the average absolute error of load forecasting is 6.912%, and the prediction accuracy is improved by 49.4%. It is concluded that the load forecasting model proposed in this article has certain significance for guiding industrial users in short and medium term loads forecasting.

**Keywords:** load forecasting; Markov correction; autoregressive moving average; short and medium term characteristics

## 0 引言

对含光储微电网系统的工业用户而言, 准确进行负荷预测能够为负荷分级调控、储能充放电控制策略实施、减少分布式光伏“弃光”、微电网经济效益评估等“源-网-荷-储”过程提供重要的决策基础。国内外专家学者在负荷预测方面取得了一定研究成果: 清华大学康重庆等<sup>[1-3]</sup>探讨了不同时间尺度下负荷预测的特点及方法, 深入分析了负荷预测常用技

术方案的优缺点及研究方向, 并结合国内外研究进展提出了指导意见; 张明泽等<sup>[4-6]</sup>研究了台区、居民等负荷的短期预测方案, 形成了负荷预测的分析管理系统; 彭显刚等<sup>[7]</sup>分析了采用神经网络模型实现短期负荷预测的途径, 为中短期负荷预测的研究提供了理论及实践支撑; 赵渊等<sup>[8]</sup>建立了非参数自回归模型对短期负荷进行预测, 有效剔除了坏数据对预测结果的干扰, 避免了主观因子对短期负荷预测的影响; 牛东晓等<sup>[9]</sup>在分析自回归条件异方差模型、

人工神经网络模型和支持向量机模型的基础上,提出了基于模糊神经网络的组合预测模型;张涛等<sup>[10-11]</sup>采用马尔科夫链对微电网系统中的负荷进行短期预测,一定程度上提高了日前预测的精度;DUDEK G 等<sup>[12-13]</sup>采用模糊聚类及非参数回归方法实现了日负荷预测;林涵等<sup>[14-16]</sup>分别基于层级注意力机制(temporal channel attention, TCA)-一维卷积神经网络(convolutional neural network, CNN)-长短期记忆(long short term memory, LSTM)网络等实现了短期负荷的可靠预测;此外,GERMI M B 等<sup>[17-19]</sup>分别提出基于高斯过程及多目标算法的短期负荷预测方法及负荷区间多模型综合预测方法,有效降低了预测误差的波动,大幅度降低了日前负荷预测的误差,为中长期负荷预测提供了建模思路,但算法流程较为复杂,且仅针对 24h 负荷进行预测;黄元生等<sup>[20]</sup>采用滑动平均模型和灰色预测模型进行年负荷预测,消除了负荷预测的偶然因素;李滨等<sup>[21]</sup>从气象角度入手,研究了基于气象因子模糊粒化的短期日负荷预测方法;唐俊杰、蒋敏等<sup>[22-23]</sup>分别提出了日周期自回归短期负荷预测模型、日均负荷预测的在线序列极限支持向量回归算法及修正方法;张贲<sup>[24-25]</sup>等建立了短期及中长期负荷预测的误差修正模型,为本文负荷预测的误差修正提供了解决方案和建模思路。

当前,国内外对于用户负荷的研究多数基于专家系统、神经网络算法、深度学习<sup>[26]</sup>等算法及模型展开,虽然部分模型具有较高精度,但是建模过程较繁琐,对自变量数量、自变量准确度及自变量间相关性的要求较高,故在实际工程中应用较少<sup>[1-4]</sup>。

为实现对工业用户中短期负荷的可靠预测,本文分析工业用户负荷历史日均功率曲线特性,采用历史负荷数据训练自回归滑动平均(auto-regressive moving average, ARMA)模型,实现对中短期负荷的预测,并采用马尔科夫残差修正算法对预测结果进行修正。

## 1 自回归滑动平均预测模型

自回归滑动平均模型是在自回归(auto-regression, AR)模型和滑动平均(moving average, MA)模型的基础上进行时间序列预测的算法,其预测步骤如下:

1) 时间序列的零均值平稳化处理。通过白噪声检验判定该时间序列是否具有平稳性,进而通过式

(1)~式(3)白噪声检验确定该平稳序列是否为白噪声。当白噪声检验系数 $\alpha=0.05 > Q$ 或 $\alpha=0.05 > L_B$ 时,说明其为非白噪声序列,可以进行后续步骤。

$$Q(N, m) = N \sum_{k=1}^m r_k^2 \sim \chi^2(m) \quad (1)$$

$$L_B(N, m) = N(N+2) \sum_{k=1}^m \frac{r_k^2}{N-k} \sim \chi^2(m) \quad (2)$$

$$\alpha=0.05 > Q \approx L_B \quad (3)$$

式中: $Q$ 为时间序列的 $Q$ 统计量; $L_B$ 为时间序列的 $LB$ 统计量; $m$ 为给定的延迟期数; $N$ 为序列样本数; $k$ 为步数; $r_k$ 为自相关系数; $\chi^2(m)$ 为自由度 $m$ 下的卡方分布。

2) 确定最佳阶数。在确定序列为平稳且非白噪声序列后,根据自相关系数、偏自相关系数确定模型阶数。自相关与偏自相关理论模式见表 1。

表 1 自相关与偏自相关理论模式

自相关系数	偏自相关系数	模型定阶
拖尾	$p$ 阶截尾	AR( $p$ )模型
$q$ 阶截尾	拖尾	MA( $q$ )模型
拖尾	拖尾	ARMA( $p, q$ )模型

3) 模型参数估计。已知模型阶数 $p$ 、 $q$ 后,利用最小二乘法对模型进行验证。

4) 模型应用。利用已选定的阶数,对未知的时序进行预测,进而对其预测误差进行计算。

## 2 基于马尔科夫残差修正的自回归滑动平均预测模型

受样本容量、样本数据准确度等因素影响,ARMA模型的预测结果会在一定范围内出现随机波动的现象,存在较大误差。马尔科夫残差修正算法在预测结果回归修正方面具有显著优势,故为了进一步修正ARMA模型的预测结果,提高模型预测准确度,采用马尔科夫残差修正算法对ARMA模型预测结果进行修正。

马尔科夫残差修正算法是根据序列当前所处状态及后续变化趋势,预测其在未来中短期可能出现的状态,在解决随机波动大的问题中有显著优势。

马尔科夫残差修正算法的步骤如下:

1) 记录时间序列中各时刻状态实测值 $X'_i$ ,以及ARMA模型预测得到的各时刻状态预测值 $X_i$ ,

并求其相对误差  $\varepsilon_i$ 。

$$\varepsilon_i = \frac{X_i - X'_i}{X'_i} \quad (4)$$

2) 各相对误差  $\varepsilon_i$  归一化处理。因各相对误差存在正值和负值, 且其所在区间范围较大, 故利用式 (5) 对其进行归一化处理, 从而将误差限制在 [0,1] 区间内。归一化处理后的相对误差  $\varepsilon'_i$  为

$$\varepsilon'_i = \frac{\varepsilon_i - \varepsilon_{i\min}}{\varepsilon_{i\max} - \varepsilon_{i\min}} \quad (5)$$

式中:  $\varepsilon_{i\min}$  为归一化前最小相对误差;  $\varepsilon_{i\max}$  为归一化前最大相对误差。

3) 对归一化后的相对误差进行区间划分。根据式 (6) 黄金分割法计算区间的分割点, 将区间划分为  $n$  个量级。

$$\lambda_i = \Omega^q \bar{G} |q| < n \quad i = 1, 2, 3, \dots, n \quad (6)$$

式中:  $\lambda_i$  为第  $i$  个状态区间节点;  $\bar{G}$  为归一化后相对误差的均值; 黄金分割率  $\Omega$  为 0.618;  $q$ 、 $n$  的取值由  $\bar{G}$  而定, 但其值须保证由所划分区间得到的状态转移矩阵没有一行全为 0, 否则重新选择  $q$ 、 $n$  的值, 并重新划分区间。

4) 根据式 (6) 求出  $\lambda_1$ 、 $\lambda_2$ 、 $\dots$ 、 $\lambda_n$ , 进而得到

其状态区间为  $[0, \lambda_1)$ 、 $[\lambda_1, \lambda_2)$ 、 $\dots$ 、 $[\lambda_n, 1]$ , 对其进行反归一化处理, 可将其还原至原相对误差区间。

5) 根据状态转移表, 计算马尔科夫一阶转移矩阵  $\mathbf{P}^{(1)}$  为

$$\mathbf{P}^{(1)} = \begin{bmatrix} P_{11} & P_{12} & \dots & P_{1n} \\ P_{21} & P_{22} & \dots & P_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ P_{n1} & P_{n2} & \dots & P_{nn} \end{bmatrix} \quad (7)$$

6) 以第  $k$  组数据为初始状态, 其状态向量  $\mathbf{P}^{(0)}$  为  $(k_1, k_2, \dots, k_n)$ , 则第  $k+1$  组数据的状态向量为

$$\mathbf{P}^{(k+1)} = \mathbf{P}^{(0)} \cdot \mathbf{P}^{(1)} = (k_1, k_2, \dots, k_n) \cdot \begin{bmatrix} P_{11} & P_{12} & \dots & P_{1n} \\ P_{21} & P_{22} & \dots & P_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ P_{n1} & P_{n2} & \dots & P_{nn} \end{bmatrix} \quad (8)$$

根据第  $k+1$  组数据状态向量所处状态区间得出其相对误差, 进而得出修正后的预测值。

7) 计算修正后的预测误差, 并与原 ARMA 模型预测误差进行对比, 得出预测准确度是否满足实际工程需求, 若不满足工程需求, 则进一步更换模型  $q$ 、 $n$  参数, 重新进行上述修正过程。

基于马尔科夫残差修正的自回归滑动平均模型预测流程如图 1 所示。

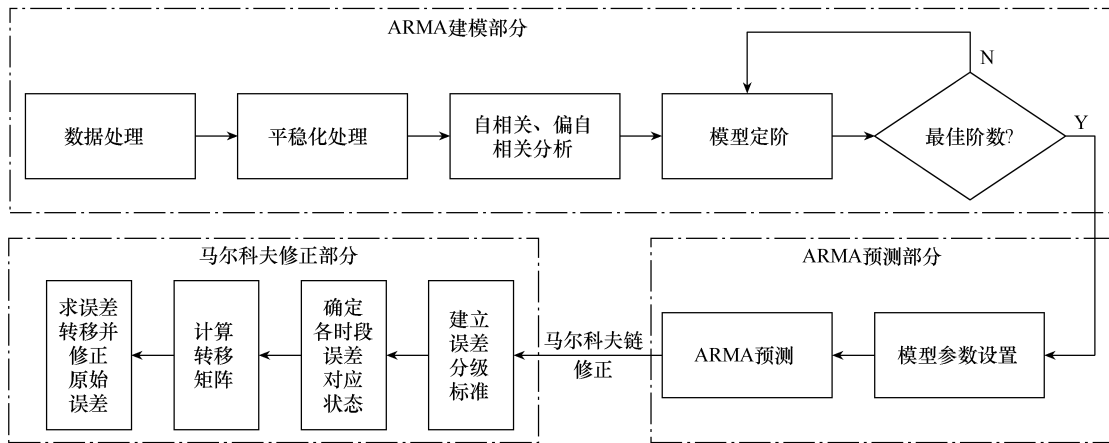


图 1 基于马尔科夫残差修正的自回归滑动平均模型预测流程

### 3 算例分析

#### 3.1 工程案例

以某 110kV 大工业用户为研究对象, 选取 2023 年 10 月 16 日至 2024 年 1 月 7 日的日负荷功率数据作为负荷预测的样本数据。该工业用户的负荷功率曲线如图 2 所示。

由图 2 可以看出, 该工业用户的日均功率呈现明显的周期性变化, 循环周期为 7 天。取前 70 组数据作为训练数据 (测试数据), 后 14 组数据作为模型校验数据 (校验数据)。

#### 3.2 ARMA 模型负荷预测

采用 ARMA 模型进行中短期负荷预测前, 需先进行序列平稳化处理。依次对 2023 年 10 月 16 日至




图 2 工业用户负荷功率曲线

2023 年 12 月 24 日的负荷功率数据进行周期差分、二次差分处理。平稳化处理后的序列如图 3 所示。

由图 3 可以看出，经周期差分、二次差分处理后，原序列已符合 ARMA 模型建模的基本条件。 $Q$  统计量和 LB 统计量分别为  $Q(70,8)=0.0271$ 、 $L_B(70,8)=$




图 3 平稳化处理后序列

$0.0208$ ，根据白噪声检验系数  $\alpha=0.05 > Q \approx L_B$  可知，该时间序列为非白噪声序列，且其自相关系数、偏自相关系数逐渐稳定在 0，由此可知该二次差分时间序列为稳定序列。自相关分析如图 4 所示，偏自相关分析如图 5 所示。




图 4 自相关分析

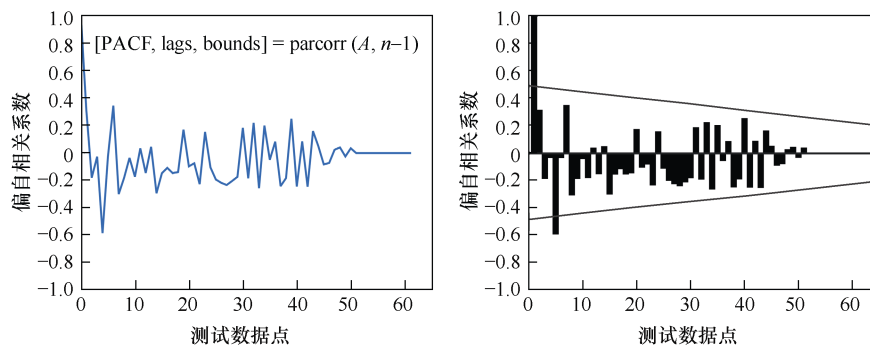


图 5 偏自相关分析

由图 4 和图 5 可以看出，自相关系数在 4 阶后出现截尾，偏自相关系数在 5 阶后出现截尾，故此时该时间序列稳定，且该序列所属模型为 ARMA(5,4)。

在此基础上，ARMA 模型进行一次一阶差分还原和一次周期差分还原，得出 2023 年 12 月 24 日之后 14 天的 ARMA 模型预测数据见表 2。负荷功率实测值与预测值对比如图 6 所示。

由表 2 和图 6 可知，负荷功率的 ARMA 模型

预测值总体小于实测值；ARMA 模型的预测误差绝对值最小为 2.194%，最大为 39.436%，平均为 12.879 8%；ARMA 模型的预测结果与实际值存在一定偏差，故需对 ARMA 模型进行进一步优化，提高其预测准确度。

### 3.3 负荷预测结果的修正

以 2024 年 1 月 3 日预测结果为例，负荷日均功率实测值为 2 112.000kW，预测值为 1 801.618kW，

表 2 ARMA 模型负荷预测数据

时间	实测值/kW	预测值/kW	残差/kW	预测误差/%
2023-12-25	1 680.938	1 609.156	-71.782	-4.270
2023-12-26	2 018.271	1 800.236	-218.035	-10.803
2023-12-27	1 941.042	1 854.628	-86.414	-4.452
2023-12-28	2 128.042	2 055.674	-72.368	-3.401
2023-12-29	2 128.729	1 840.800	-287.929	-13.526
2023-12-30	1 679.792	1 352.475	-327.317	-19.486
2023-12-31	834.854	590.946	-243.908	-29.216
2024-01-01	1 884.667	1 527.122	-357.545	-18.971
2024-01-02	2 002.688	1 845.278	-157.410	-7.860
2024-01-03	2 112.000	1 801.618	-310.382	-14.696
2024-01-04	2 097.104	2 023.963	-73.141	-3.488
2024-01-05	1 821.188	1 861.138	39.950	2.194
2024-01-06	1 404.563	1 284.913	-119.650	-8.519
2024-01-07	979.458	593.202	-386.256	-39.436




图 6 负荷功率实测值与 ARMA 模型预测值对比  
预测误差为-14.696%。对 2023 年 12 月 25 日至 2024 年 1 月 2 日各预测误差进行归一化处理，得到原始预测误差及其归一化结果见表 3。

表 3 原始预测误差及其归一化结果

时间	预测误差/%	归一化结果
2023-12-25	-4.270	0.966
2023-12-26	-10.803	0.713
2023-12-27	-4.452	0.959
2023-12-28	<b>-3.401</b>	1.000
2023-12-29	-13.526	0.608
2023-12-30	-19.486	0.377
2023-12-31	<b>-29.216</b>	0
2024-01-01	-18.971	0.397
2024-01-02	-7.860	0.827

对上述归一化后的预测误差进行区间划分。由表 3 可知，归一化后误差的均值  $\bar{G}=0.6497$ ，将归一化数据分为 3 个状态区间， $q$  取  $\pm 0.8$ ，由式 (6) 得出状态区间  $[0,1]$  的两个分割点，即  $\lambda_1=0.353666$ ， $\lambda_2=0.763857$ ，进而对 3 个状态区间进行反归一化处理，得到还原后相对误差的 3 个状态区间分别为  $Q_1[-29.216\%, -20.086\%]$ 、 $Q_2(-20.086\%, -9.497\%]$ 、 $Q_3(-9.497\%, -3.401\%]$ 。分别以  $Q_1$ 、 $Q_2$ 、 $Q_3$  为区间节点对表 3 中的预测误差进行区间划分，未在区间内的取最邻近区间，得到负荷预测误差状态区间见表 4。

表 4 负荷预测误差状态区间

时间	预测误差/%	状态区间
2023-12-25	-4.270	$Q_3$
2023-12-26	-10.803	$Q_2$
2023-12-27	-4.452	$Q_3$
2023-12-28	<b>-3.401</b>	$Q_3$
2023-12-29	-13.526	$Q_2$
2023-12-30	-19.486	$Q_2$
2023-12-31	<b>-29.216</b>	$Q_1$
2024-01-01	-18.971	$Q_2$
2024-01-02	-7.860	$Q_3$

根据表 4 的状态区间，可得出 ARMA 模型负荷预测结果的状态转移情况，进而可以求得马尔科夫残差修正算法的状态转移表见表 5。

表 5 状态转移表

状态区间	$Q_1$	$Q_2$	$Q_3$	合计
$Q_1$	0	1	0	1
$Q_2$	1	1	2	4
$Q_3$	0	2	1	3
合计	1	4	3	

以 2024 年 1 月 2 日的负荷功率状态为初始状态，该初始状态的初始向量为  $(0, 0, 1)$ ，则 2024 年 1 月 3 日的状态向量  $P$  为

$$P=(0, 0, 1) \cdot P^{(1)}=(0, 0, 1) \cdot \begin{bmatrix} 0 & 1 & 0 \\ \frac{1}{4} & \frac{1}{4} & \frac{1}{2} \\ 0 & \frac{2}{3} & \frac{1}{3} \end{bmatrix} = \left( 0, \frac{2}{3}, \frac{1}{3} \right) \quad (9)$$

即 2024 年 1 月 3 日误差所处的状态区间在  $Q_2$  的概

率远大于其在  $Q_1$ 、 $Q_3$  的概率, 故待测日修正的区间范围为  $(-20.086\%, -9.497\%]$ , 进而可以求得待测日负荷修正值区间为  $(1\ 990.672\text{kW}, 2\ 254.446\text{kW})$ 。取该负荷修正区间的中间值  $2\ 122.559\text{kW}$  作为最终修正后结果。则该日负荷功率由  $1\ 801.618\text{kW}$  修正为

$2\ 122.559\text{kW}$ , 预测误差由  $-14.696\%$  修正为  $0.5\%$ 。

同理, 采用马尔科夫残差修正算法求得 2024 年 1 月 4 日至 2024 年 1 月 7 日的修正区间、修正前预测误差、修正后功率值及修正后误差。采用马尔科夫残差修正算法前后的负荷预测结果见表 6。

表 6 采用马尔科夫残差修正算法前后的负荷预测结果

日期	实测值/kW	预测值/kW	原始误差/%	修正区间	修正值/kW	修正误差/%
2024-01-02	2 002.688	1 845.278	-7.860	初始状态区间 $Q_3$ , 初始向量为 $(0, 0, 1)$		
2024-01-03	2 112.000	1 801.618	-14.696	$Q_2$	2 122.559	0.50
2024-01-04	2 097.104	2 023.963	-3.488	$Q_3$	2 165.950	3.28
2024-01-05	1 821.188	1 861.138	2.194	$Q_3$	1 991.551	9.35
2024-01-06	1 404.563	1 284.913	-8.519	$Q_3$	1 374.949	-2.11
2024-01-07	979.458	593.202	-39.436	$Q_1$	790.173	-19.32

该用户负荷功率实测值、ARMA 模型预测值及马尔科夫残差修正值对比如图 7 所示。




图 7 负荷功率预测结果对比

由表 6 和图 7 可知, 在 2024 年 1 月 4 日至 2024 年 1 月 7 日期间, ARMA 模型的预测误差绝对值平均为  $13.67\%$ , 马尔科夫残差修正后的预测误差绝对值最大为  $19.32\%$ , 最小为  $0.50\%$ , 均值为  $6.912\%$ 。由此可以看出, 马尔科夫残差修正算法在用户负荷功率预测值修正方面具有明显效果, 负荷功率预测准确度得到了大幅提升。

不同模型的预测结果对比见表 7。由表 7 可知, 与文献[9]的支持向量机、神经网络模型相比, 本文模型的预测准确度虽略显不足, 但预测速度的优势明显; 与文献[4]的回归分析模型、边缘计算模型和文献[10]的单链马尔科夫模型相比, 本文模型的预测准确度有明显优势; 文献[22]的改进日周期自回归模型仅针对台区配变进行研究, 所选用台区配变的负荷日变化较小且无明显周期性变化, 预测数据的日关联性强, 此时改进日周期自回归模型的预测准确度较高, 同时数据处理复杂度较低, 而本文的研究对象为负荷具有明显周期性变化的工业用

户, 单一自回归模型无法实现对此类数据的分析。由此可见, 本文提出的基于马尔科夫残差修正的自回归滑动平均模型既能满足工业用户中短期负荷预测的准确度需求, 也能兼顾计算速度。

表 7 不同模型预测结果对比

模型		预测误差绝对值均值/%	平均计算时间/min
本文模型	马尔科夫残差修正的 ARMA 模型	6.912	0.051
文献[4]	回归分析模型	16.680	0.012
	边缘计算模型	9.190	0.063
文献[9]	数据挖掘的支持向量机模型	4.494	0.098
	神经网络模型	6.625	0.084
文献[10]	单链马尔科夫模型	9.750	0.037
	双耦合马尔科夫模型	2.570	0.103
文献[22]	改进日周期自回归模型	6.430	0.022
	基本日周期自回归模型	7.550	0.063
	改进周周期自回归模型	8.610	0.071

## 4 结论

本文以工业用户中短期负荷预测为研究对象, 提出了一种基于马尔科夫残差修正的自回归滑动平均模型, 并结合工程案例验证了该模型的实际应用效果。工程案例表明, ARMA 模型预测误差绝对值均值为  $13.67\%$ , 经马尔科夫残差修正后的预测误差绝对值均值为  $6.912\%$ , 准确度提升了近  $50\%$ 。本文将传统 ARMA 模型与马尔科夫残差修正算法相结合, 弥补了传统单一 ARMA 模型预测准确度不高的不足, 且与神经网络等其他模型相比, 本文所提模

型的计算复杂度更低。

工业用户实际负荷的突变性、周期性差异及样本数据量等均会导致预测结果与实测值存在一定偏差,但本文模型已能够满足用户负荷分级调控、产能规划等需求,对指导工业用户的中短期负荷预测及生产调度具有一定的指导意义。

### 参考文献

- [1] 康重庆,夏清,张伯明. 电力系统负荷预测研究综述与发展方向的探讨[J]. 电力系统自动化, 2004(17): 1-11.
- [2] WILLIS H L. Spatial electric load forecasting[M]. Second edition. New York: Marcel Dekker, 2002.
- [3] 陆秋瑜,马千里,魏鞞,等. 基于置信容量的风场配套储能容量优化配置[J]. 电工技术学报, 2022, 37(23): 5901-5910.
- [4] 张明泽,栾文鹏,艾欣,等. 基于边缘计算的台区短期负荷预测方法[J]. 电测与仪表, 2024, 61(4): 93-99.
- [5] 江晶晶,窦真兰,杨海涛,等. 贫乏信息下基于深度迁移学习的智慧建筑负荷预测方法[J]. 电气技术, 2022, 23(5): 55-61, 72.
- [6] 李延珍,王海鑫,杨子豪,等. 基于非侵入式负荷分解的家庭负荷两阶段超短期负荷预测模型[J]. 电工技术学报, 2024, 39(11): 3379-3391.
- [7] 彭显刚,胡松峰,吕大勇. 基于 RBF 神经网络的短期负荷预测方法综述[J]. 电力系统保护与控制, 2011, 39(17): 144-148.
- [8] 赵渊,张夏菲,谢开贵. 非参数自回归方法在短期电力负荷预测中的应用[J]. 高电压技术, 2011, 37(2): 429-435.
- [9] 牛东晓,谷志红,邢棉,等. 基于数据挖掘的 SVM 短期负荷预测方法研究[J]. 中国电机工程学报, 2006, 26(18): 6-12.
- [10] 张涛,顾洁. 高比例可再生能源电力系统的马尔科夫短期负荷预测方法[J]. 电网技术, 2018, 42(4): 1071-1078.
- [11] 张栋梁,严健,李晓波,等. 基于马尔科夫链筛选组合预测模型的中长期负荷预测方法[J]. 电力系统保护与控制, 2016, 44(12): 63-67.
- [12] DUDEK G. Pattern similarity-based methods for short-term load forecasting—part 2: models[J]. Applied Soft Computing, 2015, 36: 422-441.
- [13] PAPARODITIS E, SAPATINAS T. Short-term load forecasting: the similar shape functional time series predictor[J]. IEEE Transactions on Power Systems, 2012, 28(4): 3818-3825.
- [14] 林涵,郝正航,郭家鹏,等. 基于 TCA-CNN-LSTM 的短期负荷预测研究[J]. 电测与仪表, 2023, 60(8): 73-80.
- [15] 赵洋,王瀚墨,康丽,等. 基于时间卷积网络的短期电力负荷预测[J]. 电工技术学报, 2022, 37(5): 1242-1251.
- [16] 崔星,李晋国,张照贝,等. 基于改进粒子群算法优化 LSTM 的短期电力负荷预测[J]. 电测与仪表, 2024, 61(1): 131-136.
- [17] GERMI M B, MIRJAVADI M, NAMIN A S S, et al. A hybrid model for daily peak load power forecasting based on SAMBA and neural network[J]. Journal of Intelligent & Fuzzy Systems: Application in Engineering and Technology, 2014, 27(2): 913-920.
- [18] 李智轩,李嘉丰,叶晓华,等. 基于 Copula 函数与多目标进化算法的负荷区间预测[J]. 电气技术, 2024, 25(6): 24-30.
- [19] 陈轩伟. 基于 BP-QR 模型的负荷区间预测[J]. 电气技术, 2022, 23(4): 14-17, 24.
- [20] 黄元生,方伟. 基于灰色傅里叶变换残差修正的电力负荷预测模型[J]. 电力自动化设备, 2013, 33(9): 105-107, 112.
- [21] 李滨,覃芳璐,吴茵,等. 基于模糊信息粒化与多策略灵敏度的短期日负荷曲线预测[J]. 电工技术学报, 2017, 32(9): 149-159.
- [22] 唐俊杰,牛焕娜,杨明皓. 基于线性相关分析的周期自回归短期负荷预测[J]. 电力系统保护与控制, 2010, 38(14): 128-133.
- [23] 蒋敏,顾东健,孔军,等. 基于在线序列极限支持向量回归的短期负荷预测模型[J]. 电网技术, 2018, 42(7): 2240-2247.
- [24] 徐扬,张紫涛. 基于遗传模拟退火算法改进 BP 神经网络的中长期电力负荷预测[J]. 电气技术, 2021, 22(9): 70-76.
- [25] 张贲,邵常宁,赵燃. 基于误差修正的短期负荷预测方法[J]. 电力自动化设备, 2015, 35(11): 152-157.
- [26] 阳曾,丁施尹,叶萌,等. 基于变分模态分解和深度学习的短期电力负荷预测模型[J]. 电测与仪表, 2023, 60(2): 126-131, 146.

收稿日期: 2024-11-06

修回日期: 2024-12-11

作者简介

惠 杰(1992—),男,河南省南阳市人,硕士,主要从事电力设备产品结构研发工作。