

文章编号: 1004-4353(2022)02-0151-07

加权 Markov 修正模糊信息粒的 电力负荷区间预测

童林, 何青青

(六盘水师范学院 物理与电气工程学院, 贵州 六盘水 553004)

摘要: 针对电力负荷预测存在波动性且预测精度不高的问题, 提出一种基于加权马尔可夫(Markov)修正模糊信息粒的电力负荷区间预测方法. 该方法首先对电力负荷数据序列进行基于模糊信息粒化(FIG)的空间窗口重构, 以此得到电力负荷模糊信息粒和电力负荷的各阶自相关系数; 然后建立由基于 FIG 和长短期记忆网络(LSTM)组合的模型(FIG-LSTM), 以此获得能够预测不同模糊粒的 3 组 LSTM 模型; 最后建立加权 Markov-FIG-LSTM 模型, 并通过消除 3 组 LSTM 模型中的预测误差得到电力负荷预测区间和趋势值. 实例分析表明, Markov-FIG-LSTM 模型的 RMSE、MAE 和 MAPE 指标比 FIG-LSTM 模型分别降低了 4.78%、11.37% 和 11.72%, 因此该方法可为电网调度提供有效的数据支撑.

关键词: 电力负荷预测; 加权马尔可夫; 模糊信息粒化; 长短期记忆网络; 误差修正

中图分类号: TP391

文献标识码: A

Power load interval forecast based on weighted Markov modified fuzzy information granule

TONG Lin, HE Qingqing

(School of Physics and Electrical Engineering, Liupanshui Normal University, Liupanshui 553004, China)

Abstract: Aiming at the problem of fluctuation and low precision in power load forecasting, a method of power load interval prediction based on weighted Markov modified fuzzy information granules was proposed. Firstly, the spatial window of power load data series is reconstructed based on fuzzy information granulation (FIG), and the order autocorrelation coefficients of fuzzy information granules and power load are obtained. Then, a combination model (FIG-LSTM) based on FIG and LSTM was established to obtain three groups of LSTM model that could predict different fuzzy particles. Finally, the weighted Markov-FIG-LSTM model is established, and the power load prediction interval and trend value are obtained by eliminating the prediction error of three groups of LSTM models. The example analysis shows that the RMSE, MAE and MAPE indexes of the Markov-FIG-LSTM model are reduced by 4.78%, 11.37% and 11.72% respectively compared with the FIG-LSTM model. Therefore, this method can provide effective data support for power grid dispatching.

Keywords: power load forecast; weighted Markov; fuzzy information granulation; long and short-term memory network; error correction

0 引言

电力系统的短期负荷预测对智能电网的构

建、电力的生产计划、发电机组的优化调度等具有重要意义^[1]. 近年来, 随着机器学习理论的不

收稿日期: 2021-08-22

作者简介: 童林(1995—), 男, 讲师, 研究方向为机器学习、智能控制.

展,一些机器学习方法被应用于电力负荷预测.例如:文献[2]和[3]提出了一种基于智能算法改进的BP网络(back propagation, BP)的电力负荷预测方法,该方法虽具有建模简单和训练时间短等优点,但仍然存在算法易早熟收敛以及误差平方和容易导致出现局部极小点等问题^[4].文献[5]提出了一种基于支持向量机(support vector machine, SVM)的电力负荷预测模型,该模型虽然可实现电力负荷的高维空间映射和预测,但在参数选择方面需进一步优化,且使用优化算法优化SVM参数过程中存在容易陷入局部最优和早熟等问题^[6].文献[7]提出了一种使用长短时记忆(long short-term memory, LSTM)网络对区域电力负荷进行预测的方法,该方法虽具有较高的预测精度,但在负荷变动较大时预测精度降低.

由于使用预测模型对时间序列数据进行预测均会产生一定的误差,因此一些学者提出了一些修正误差的方法.例如:文献[8]提出了一种基于误差修正的光伏预测方法,该方法虽考虑到了光伏出力预测误差,并基于Copula理论和 k 均值聚类算法对光伏预测值进行了修正,但存在 k 值选择困难、计算复杂等问题.文献[9]和文献[10]的作者分别利用不同的误差修正函数对风电功率进行了预测,这2种函数虽然可实现对预测误差的补偿与修正,但由于这2种函数使用固定的修正因子使得其缺乏良好的泛化能力.上述预测方法都是对电力负荷点值进行预测的,而研究^[11]显示采用区间预测技术可以更好地反映输出功率的波动性和随机性.基于上述研究,本文针对单一负荷定量预测模型不能表征预测结果和预测电力负荷波动范围精度较低的问题,提出一种基于加权马尔可夫(Markov)修正模糊信息粒的电力负荷区间预测模型,并通过实例分析验证了本文方法的有效性.

1 模型描述

加权Markov修正模糊信息粒的电力负荷区间预测修正模型的结构见图1.为便于表述,本文在下文中将电力负荷简称为负荷.

负荷区间预测修正模型主要分为3个部分:

1)电力负荷模糊信息粒化(fuzzy information granulation, FIG)部分.该部分的主要功能为:获取负荷模糊信息粒,划分FIG窗口;选择隶属度函数,计算隶属度函数参数;对细颗粒度下的负荷数据进行FIG操作,提取各窗口内模糊粒的有效信息;确定负荷的合理区间上界(Up)、下界(Low)及趋势值(R).

2)电力负荷预测部分.该部分的主要功能为:建立基于LSTM的负荷预测模型,优化LSTM网络参数;获取负荷模糊信息粒的 Up 、 Low 及 R 的预测值及其与实际值相减所得的误差值;提取 Up 、 Low 及 R 的各阶自相关系数,确定下一部分的输入参数.

3)误差修正部分.该部分的主功能为:建立加权Markov修正模型,计算负荷误差转移概率和修正后的预测值.

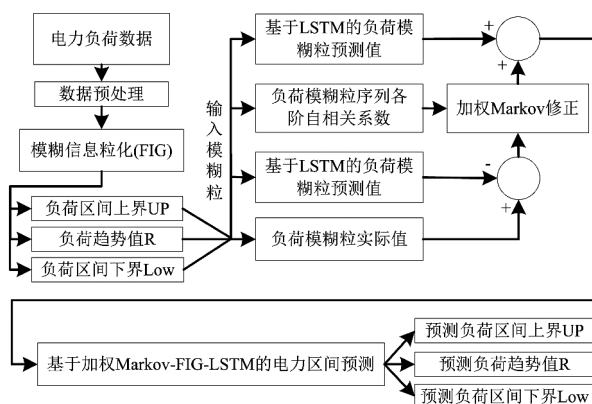


图1 电力负荷区间预测修正模型

需要说明的是,图1中出现了两次基于LSTM的负荷变量预测值,但每次出现时其具体用途不同,其中与实际值相连接的预测值是用于计算Markov链状态转移概率矩阵,与Markov修正相连接的预测值是用于计算最终的修正量.

2 负荷区间预测模型

2.1 负荷模糊信息粒化模型

1997年Zadeh^[12]首次提出了信息粒化模型,该模型可用以处理相似度较大或难以区分的数据,且便于研究信息的形成、表示、粗细及语义解释等.信息造粒方法主要有模糊集方法、粗糙集方法及商空间方法.由于基于模糊集方法的信息造

粒模型能够准确反映事物特性和划分复杂多变的电力负荷数据^[13],因此本文将该模型作为信息粒化的工具. 负荷时间序列 FIG 的建模主要分为如下两个步骤:

1) 划分原始数据的窗口. 划分数据窗口的目的是简化数据序列,进而便于粒化研究. 划分数据窗口的方法是在数据序列上选择合适的窗口(即子间隔)大小进行划分. 为使每个窗口具有相等的粒化数目,本文将时间窗口设为固定值. 假定负荷时间数据序列为 $X = (x_1, x_2, \dots, x_n)$, 定义 k ($1 \leq k \leq n$) 为划分的窗口数量,则负荷的具体粒化过程可表示为如图 2 所示的流程. 图 2 中,负荷时间数据共被划分为 k 个窗口,每个窗口的粒化数目为 n/k .




图 2 负荷时间序列的 FIG 流程图

2) 选择隶属函数. 选择隶属函数的目的是表征图 2 窗口中的数据,进而选择合适的信息粒度刻画规则. 由于三角型隶属函数具有构造简单和应用范围广的优势,因此本文采用该函数确定负荷的合理区间. 三角型隶属函数的表达式为:

$$A(x, a, b, c) = \begin{cases} 0, & x < a; \\ \frac{x-a}{b-a}, & a \leq x \leq b; \\ \frac{c-x}{c-b}, & b < x \leq c; \\ 0, & x > c. \end{cases} \quad (1)$$

式中, x 为模糊论域中的变量, a 和 c 分别为模糊上界和模糊下界, b 为模糊核参数. 假设已知单个窗口由 N/K 个连续点 $\{x_1, x_2, \dots, x_{N/K}\}$ 组成,且这些点按升序排列. 数据点 $\{x_1, x_2, \dots, x_B\}$ 位于模糊集的左侧边界,剩余点位于右侧. 本文参考文献^[14]中的方法计算 a 、 b 和 c 的参数.

计算 $Q(a)$ 的公式为:

$$Q(a) = \frac{\sum_{i=1}^B (x_i - a)}{(b-a)^2} = \frac{\sum_{i=1}^B x_i - Ba}{(b-a)^2}. \quad (2)$$

计算 $Q(a)$ 导数的公式为:

$$\frac{dQ(a)}{da} = \frac{2 \sum_{i=1}^B x_i - B(b-a)}{(b-a)^3}. \quad (3)$$

当 $Q(a)$ 的导数为 0 时, a 为:

$$a = (2 \sum_{i=1}^B x_i) / B - b. \quad (4)$$

计算 $Q(c)$ 的计算公式为:

$$Q(c) = \sum_{i=B+1}^{N/K} (x_i - c) / (b-c)^2 = \left[\sum_{i=B+1}^{N/K} x_i - b(N/K - B) \right] / (b-c)^2. \quad (5)$$

当 $Q(c)$ 为最大值时, c 为:

$$c = (2 \sum_{i=B+1}^{N/K} x_i) / (N/K - B) - b. \quad (6)$$

上述公式中,核参数 b 的取值为:

$$\begin{cases} b = \frac{1}{2} (x_{\frac{N/K}{2}} + x_{\frac{N/K}{2}+1}), & N/K \text{ is even;} \\ b = x_{\frac{N/K+1}{2}}, & N/K \text{ is odd.} \end{cases} \quad (7)$$

2.2 LSTM 模型

LSTM 网络是一种时间循环神经网络,它不仅能降低发生梯度消失或梯度爆炸的风险,还能够较好地保持长时间记忆. LSTM 网络主要包括输入门 i_t 、遗忘门 f_t 和输出门 o_t ^[15],具体结构如图 3 所示. 遗忘门的功能为通过读取 LSTM 网络的上一层输出 h_{t-1} 和当前层输入 x_t 来选择 LSTM 网络丢弃的信息,其计算公式为:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + d_f). \quad (8)$$

式中, σ 为激活函数, W_f 为遗忘门的权重系数, d_f 为遗忘门的偏置项.




图 3 LSTM 网络结构图

输入门的功能是表征在单元格中添加了多少新信息和生成候选更新值 \tilde{C}_t , 其计算公式为:

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + d_i), \quad (9)$$

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + d_c). \quad (10)$$

式中, W_i 和 W_c 为输入门和更新值 \tilde{C}_t 的权重系数, d_i 和 d_c 为输入门和更新值 \tilde{C}_t 的偏置项. 更新 \tilde{C}_t 后, LSTM 将 $(C_{t-1}f_t + i_t\tilde{C}_t)$ 作为新的候选值. 输出门的 o_t 和 Sigmoid 函数用于确定输出的部分, 其计算公式为:

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + d_o), \quad (11)$$

$$h_t = o_t \tanh(\tilde{C}_t). \quad (12)$$

式中, W_o 为输出门的权重系数, d_o 为输出门的偏置项.

3 加权 Markov 修正模糊信息粒模型

Markov 模型可根据系统当前状态推测下一时刻的概率分布, 对预测的偏差值具有良好的修复功能, 因此本文将该模型作为修正 LSTM 预测误差的工具^[16]. 构建加权 Markov 修正模型的具体过程为(以未经过模糊粒化的负荷数据 $X = (x_1, x_2, \dots, x_n)$ 为例)^[17]:

1) 计算 Markov 自相关权重. 根据负荷序列的自相关系数计算 Markov 自相关权重, 其计算公式^[18]为:

$$r_l = \frac{\sum_{i=1}^{n-l} (x_i - \bar{x})(x_{i+l} - \bar{x})}{\sqrt{\sum_{i=1}^{n-l} (x_i - \bar{x})^2 \sum_{i=1}^{n-l} (x_{i+l} - \bar{x})^2}}. \quad (13)$$

式中, r_l 为第 l 阶即步数为 l 的自相关系数, x_i 为第 i 时刻的负荷值, \bar{x} 为负荷序列的均值, n 为负荷数据序列的数目.

2) 状态区间的划分. 状态区间的划分方法是将实际值与预测值之间的误差序列 $\delta^{(0)} = \{\delta^{(0)}(1), \delta^{(0)}(2), \dots, \delta^{(0)}(n)\}$ 划分为 E_1, E_2, \dots, E_m 等状态区间, 其中的任意区间可表示为:

$$E_i \in [e_{i-1}, e_i], i = 1, 2, \dots, m. \quad (14)$$

其中, e_{i-1} 和 e_i 分别为第 i 个误差状态区间的下限值和上限值.

3) 计算状态转移概率矩阵. 当发生误差状态转移的总数目为 E_i , 由误差状态 E_i 经过 1 步转移到误差状态 E_j 的数目为 M_{ij} 时, 此时误差状态转移概率为:

$$p_{ij}^{(1)} = M_{ij} / M_i, i, j = 1, 2, \dots, m. \quad (15)$$

由 $m \times m$ 组转移概率得到的 1 阶误差状态转移概率矩阵为:

$$P^{(1)} = \begin{bmatrix} p_{11}^{(1)} & p_{12}^{(1)} & \cdots & p_{1m}^{(1)} \\ p_{21}^{(1)} & p_{22}^{(1)} & \cdots & p_{2m}^{(1)} \\ \vdots & \vdots & \ddots & \vdots \\ p_{m1}^{(1)} & p_{m2}^{(1)} & \cdots & p_{mm}^{(1)} \end{bmatrix}. \quad (16)$$

由 $P^{(1)}$ 可得 l 阶误差状态转移概率 $P^{(l)}$ 为 $[P^{(1)}]^l$.

4) 计算状态转移加权向量矩阵. 首先通过状态转移概率矩阵获取状态转移概率矩阵初始状态对应的行向量以及通过现有状态获取新的概率转移矩阵, 然后对新概率转移矩阵中的 i 列向量加权求和, 并以其作为最终的预测概率 P_i , 即:

$$P_i = \sum_{l=1}^m \theta_l P_i^{(l)}. \quad (17)$$

式中, θ_l 为根据各阶自相关权重计算得到的加权系数, 其计算公式为:

$$\theta_l = |r_l| / \sum_{l=1}^m |r_l|, l \leq m. \quad (18)$$

式中, l 为阶数. 根据式 (17) 得到 P_i 后, 将 $\max\{P_i, i = 1, 2, \dots, m\}$ 所对应的状态 i 作为预测值所处的误差区间 $E_i \in [e_{i-1}, e_i]$.

5) 预测值的修正. 计算修正系数 \hat{Y} 的公式为:

$$\hat{Y} = \left(e_{i-1} \frac{p_{i-1}}{p_{i-1} + p_{i+1}} + e_i \frac{p_{i+1}}{p_{i-1} + p_{i+1}} \right). \quad (19)$$

利用修正系数计算预测值 x 的公式为:

$$\hat{x} = x \times \hat{Y}. \quad (20)$$

4 算例分析

4.1 实验准备

选取 2010 年 12 月份澳大利亚某地区的负荷集作为实验数据来验证本文所提模型的有效性, 其中将 1 日至 28 日的负荷作为训练集, 将 29 日、30 日及 31 日的负荷作为预测集, 数据间隔时间为 0.5 h. 另外, 取 29 日和 30 日的负荷数据用于建立加权 Markov 模型, 并使用加权 Markov 模型对 31 日的负荷数据进行修正. 选取均方根误差 (RMSE)、平均绝对误差 (MAE) 和平均绝对百分比误差 (MAPE) 作为评判指标, 各指标的计算公式为:

$$RMSE = \sqrt{\sum_{i=1}^n (x_i - x_i^*)^2 / n}, \quad (21)$$

$$MAE = \sum_{i=1}^n |(x_i - x_i^*)| / n, \quad (22)$$

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{x_i - x_i^*}{x_i} \right|. \quad (23)$$

式中, n 为数据量, x 为实际负荷值, x^* 为预测负荷值(修正值也视为最终预测值)。

4.2 实例分析

4.2.1 预测值的对比分析

首先对负荷进行 FIG 操作(选择粒化窗口数为 6, 即将 24 h 的数据粒化为 8 个窗口), 由此得到的 29 日、30 日及 31 日的粒化结果(共 24 组)见图 4。




图4 负荷信息粒化结果图

由图 4 可以看出, 经过 FIG 操作后, 负荷分解为 3 种模糊信息粒(Low、Up 和 R)。本文通过计算 Low、R 和 Up 3 组预测数据的整体 RMSE、MAE 及 MAPE 来评价预测模型的性能。计算过程为首先分别计算 Low、R 及 Up 的 RMSE、MAE 及 MAPE, 然后取 RMSE、MAE 及 MAPE 的平均值。具体的计算公式为:

$$RMSE = \frac{RMSE_{Low} + RMSE_R + RMSE_{Up}}{3}, \quad (24)$$

$$MAE = \frac{MAE_{Low} + MAE_R + MAE_{Up}}{3}, \quad (25)$$

$$MAPE = \frac{MAPE_{Low} + MAPE_R + MAPE_{Up}}{3}. \quad (26)$$

4.2.2 加权 Markov 修正计算及其结果分析

由于对基于 FIG-LSTM 获得的预测值进行

加权 Markov 修正时数据组数过多, 因此本文在此仅以 Up 值为例给出计算过程。获得 Up 值后, 按照相对误差值的大小对其排列, 并将其划分为如下 4 种状态: $E_1 \in [95.53\%, 97.84\%)$, $E_2 \in [97.84\%, 100.15\%)$, $E_3 \in [100.15\%, 102.46\%)$, $E_4 \in [102.46\%, 104.77\%)$ 。

根据上述原始数据序列, 利用式(13)计算出的各阶的自相关系数分别为 0.713 0、0.299 6、0.001 9、-0.147 5, 由此绘制出的各阶自相关系数图如图 5 所示。由图 5 可知, 1 阶和 2 阶的自相关系数较高, 故本文计算加权 Markov 模型取 1 阶和 2 阶。




图5 各阶自相关系数图

由 E_1 、 E_2 、 E_3 及 E_4 状态区间分类中获得的 29 日和 30 日各个时段的状态区间分类情况如表 1 所示。

表1 误差状态划分

| | 时间段 | $E/\%$ | 状态 |
|------|-------------|--------|-------|
| 29 日 | 00:00-03:00 | 103.76 | E_4 |
| | 03:00-06:00 | 103.30 | E_4 |
| | 06:00-09:00 | 103.61 | E_4 |
| | 09:00-12:00 | 100.53 | E_3 |
| | 12:00-15:00 | 102.64 | E_4 |
| | 15:00-18:00 | 103.24 | E_4 |
| | 18:00-21:00 | 100.39 | E_3 |
| | 21:00-00:00 | 99.03 | E_2 |
| 30 日 | 00:00-03:00 | 98.20 | E_2 |
| | 03:00-06:00 | 95.53 | E_1 |
| | 06:00-09:00 | 101.79 | E_3 |
| | 09:00-12:00 | 103.97 | E_4 |
| | 12:00-15:00 | 104.77 | E_4 |
| | 15:00-18:00 | 102.25 | E_3 |
| | 18:00-21:00 | 101.92 | E_3 |
| | 21:00-00:00 | 99.69 | E_2 |

根据式(18) 计算 1 阶和 2 阶的权重,得:

$$\theta_1 = \frac{0.713}{0.713+0.2996} = 0.7041,$$

$$\theta_2 = \frac{0.2996}{0.713+0.2996} = 0.2959.$$

为预测 31 日的 Up 值,首先需计算各阶下的 Markov 转移概率矩阵,计算得:

$$\mathbf{P}^{(1)} = \begin{bmatrix} 0 & 0 & 1.000 & 0 \\ 0.500 & 0.500 & 0 & 0 \\ 0 & 0.400 & 0.200 & 0.400 \\ 0 & 0 & 0.429 & 0.571 \end{bmatrix},$$

$$\mathbf{P}^{(2)} = \begin{bmatrix} 0 & 0.400 & 0.200 & 0.400 \\ 0.250 & 0.250 & 0.500 & 0 \\ 0.200 & 0.280 & 0.212 & 0.308 \\ 0 & 0.172 & 0.331 & 0.497 \end{bmatrix}.$$

由表 1 可知,预测的 Up 值在 30 日的 21:00-00:00 和 18:00-21:00 时间段内分别处于 E_2 和 E_3 状态. 根据 Markov 转移概率矩阵可得,1 阶转移概率向量取(0.500,0.500,0,0),2 阶转移概率向量取(0.200,0.280,0.212,0.308). 由式(17) 计算出的加权 Markov 预测概率见表 2.

表 2 加权 Markov 转移概率

| 初始状态 | 权重 | 状态转移率 | | | |
|--------|-------|-------|-------|-------|-------|
| | | E_1 | E_2 | E_3 | E_4 |
| E_2 | 0.704 | 0.500 | 0.500 | 0 | 0 |
| E_3 | 0.296 | 0.200 | 0.280 | 0.212 | 0.308 |
| 加权转移概率 | | 0.411 | 0.435 | 0.063 | 0.091 |

由表 2 可知,最大加权转移概率 $\max\{\mathbf{P}_i\}$ 为 0.435,表明下一步负荷值处于 E_2 状态的概率最大. 根据式(19)对 E_2 区间进行线性插值可得预测值 x 的修正系数 \hat{Y} ,其计算过程为:

$$\hat{Y} = 97.84\% \times \frac{0.411}{0.411+0.063} + 100.15\% \times \frac{0.063}{0.411+0.063} = 98.147\%.$$

根据式(20)对预测值 x 进行修正计算得:

$$\tilde{x} = 7813.88 \times 98.147\% = 7669.09.$$

由 \tilde{x} 可得 31 日 00:00-03:00 时间段的 Up 值为 7669.09 kW·h. 再利用相同步骤对 31 日的 03:00-06:00 时间段的数据进行修正. 由于计算过程与 31 日 00:00-03:00 时间段的修正过程类似,因此本文在此仅给出修正值的计算结果(见表 3).

表 3 负荷模糊信息粒的预测结果

kW·h

| 时间段 | 实际 [Low R Up] | LSTM 预测 [Low R Up] | 加权 Markov 修正 [Low R Up] |
|-------------|---------------------------------|--------------------------------|--------------------------------|
| 00:00-03:00 | [6 227.52 7 002.23 7 506.45] | [6 662.90 7 317.49 7 813.88] | [6 381.08 7 324.76 7 669.09] |
| 03:00-06:00 | [6 246.79 6 353.02 6 603.26] | [5 669.70 5 718.02 7 096.21] | [5 429.90 5 669.11 6 983.54] |
| 06:00-09:00 | [6 744.92 7 864.22 8 543.43] | [7 089.63 7 533.89 8 846.55] | [6 943.72 7 925.83 8 816.80] |
| 09:00-12:00 | [9 037.20 9 629.53 9 924.14] | [9 248.56 10 170.08 9 207.97] | [9 058.22 10 140.93 9 294.61] |
| 12:00-15:00 | [10 068.72 10 417.96 10 613.34] | [9 354.02 9 736.23 9 893.14] | [9 711.51 9 661.62 10 236.85] |
| 15:00-18:00 | [10 226.29 10 735.25 10 836.72] | [9 489.07 10 156.76 10 477.61] | [9 298.36 10 078.92 10 547.16] |
| 18:00-21:00 | [8 552.82 8 938.99 9 589.25] | [9 603.74 10 092.44 9 950.88] | [9 410.73 10 015.10 10 162.86] |
| 21:00-00:00 | [8 236.40 8 434.42 8 532.88] | [7 971.64 8 708.27 8 812.62] | [8 229.76 9 262.26 8 588.79] |

由表 3 可以看出,利用加权 Markov 修正的预测值更接近于真实值. 由于仅通过表 3 无法判断加权 Markov 模型精度的提升效果,本文利用式(24)、(25) 及式(26) 计算了 2 种模型的整体预测性能,结果如表 4 所示. 由表 4 中的指标可知,本文提出的 Markov-FIG-LSTM 模型的 RMSE、MAE 和 MAPE 指标比 FIG-LSTM 模型分别降低了 4.78%、11.37% 和 11.72%,这表明加权 Markov 能够更好地对 LSTM 预测误差进行修正.

表 4 FIG-LSTM 模型和 Markov-FIG-LSTM 模型的整体预测性能

| 模型 | RMSE/ (kW·h) | MAE/ (kW·h) | MAPE/ % |
|-----------------|-----------------|----------------|------------|
| FIG-LSTM | 567.07 | 516.05 | 6.06 |
| Markov-FIG-LSTM | 539.94 | 457.39 | 5.35 |

5 结论

研究表明,本文提出的 Markov-FIG-LSTM

预测方法比 FIG-LSTM 预测方法能更好地预测电力负荷区间,因此本文方法能够为电力负荷调度及电网分析提供更有力的依据.在今后的研究中我们将采用迁移学习等方法来进一步改进模型,以实现小样本下的电力负荷高精度预测和提高本文方法的适用性.

参考文献:

- [1] 庄世杰,於志勇,郭文忠,等. 基于 Zoneout 的跨尺度循环神经网络及其在短期电力负荷预测中的应用[J]. 计算机科学,2020,47(9):105-109.
- [2] 王克杰,张瑞. 基于改进 BP 神经网络的短期电力负荷预测方法研究[J]. 电测与仪表,2019,56(24):115-121.
- [3] 张淑清,杨振宁,张立国,等. 基于弹性网降维及花授粉算法优化 BP 神经网络的短期电力负荷预测[J]. 仪器仪表学报,2019,40(7):47-54.
- [4] 童林,官铮. 改进鲸鱼优化支持向量机的交通流量模糊粒化预测[J]. 计算机应用,2021,41(10):2919-2927.
- [5] 胡时雨,罗滇生,阳霜,等. 基于多变量 LS-SVM 和模糊循环推理系统的负荷预测[J]. 计算机应用,2015,35(2):595-600.
- [6] 俞颖,黄风华,阮奇. 基于改进粒子群优化算法和 CRNN 的多类 SVM 分类[J]. 延边大学学报(自然科学版),2019,45(3):215-220.
- [7] 张宇帆,艾芊,林琳,等. 基于深度长短时记忆网络的区域级超短期负荷预测方法[J]. 电网技术,2019,43(6):1884-1892.
- [8] 茆美琴,洪嘉玲,张榴晨. 考虑光伏出力预测误差修正的储能优化配置方法[J]. 太阳能学报,2021,42(2):410-416.
- [9] 童林,官铮,王立威,等. 基于时序分解与误差修正的新能源爬坡事件预测[J]. 浙江大学学报(工学版),2022,56(2):338-346.
- [10] 刘帅,朱永利,张科,等. 基于误差修正 ARMA-GARCH 模型的短期风电功率预测[J]. 太阳能学报,2020,41(10):268-275.
- [11] 张娜,王守相,葛磊蛟,等. 一种光伏短期出力区间预测方法[J]. 太阳能学报,2020,41(8):173-179.
- [12] ZADEH L A. Toward a theory of fuzzy information granulation and its centrality in human reasoning and fuzzy logic[J]. Fuzzy Sets & Systems, 1997, 90(2):111-127.
- [13] 柯德营,殷业,杜军辉. 基于模糊信息粒理论的模糊控制方法[J]. 计算机仿真,2016,33(1):391-395.
- [14] PAN W, CHEN Q, ZHU M, et al. A data-driven fuzzy information granulation approach for battery state of health forecasting[J]. Journal of Power Sources, 2020,475:228716.
- [15] GREFF K, SRIVASTAVA R K, KOUTNÍK J, et al. LSTM: A search space odyssey[J]. IEEE Transactions on Neural Networks & Learning Systems, 2016,28(10):2222-2232.
- [16] 杨梓鑫,薛源,徐浩军,等. 基于 RBF 神经网络与 Markov 组合的飞行风险预测研究[J]. 系统工程理论与实践,2019,39(8):2162-2169.
- [17] JIANG X C, CHEN S F. Application of weighted Markov SCGM(1,1) model to predict drought crop area[J]. Systems Engineering-Theory & Practice, 2009,29(9):179-185.
- [18] 苗作华,刘耀林,王海军. 耕地需求量预测的加权模糊-马尔可夫链模型[J]. 武汉大学学报(信息科学版),2005(4):305-308.