

文章编号:1005-0523(2019)05-0102-07

基于指数加权移动平均多维组合模型的电力负荷预测

李颖玥¹,王 勋¹,康 琛²,万 华²,程宏波¹

(1.华东交通大学电气与自动化工程学院,江西 南昌 330013;2.国网江西省电力有限公司电力科学研究院,江西 南昌 330096)

摘要:随着电力行业的不断发展,对电力用户侧进行用电负荷预测成了满足用户用电供需平衡和电网规划的重要部分。在大数据背景下,为提高电力负荷预测结果的准确性,针对历史数据时间远近的影响,分别考虑同期历史数据和近期历史数据两类数据局限性的影响,基于时间占优的原理,引入指数加权移动平均模型对不同时刻的数据进行权重分配,提出了改进的电力负荷预测模型。以某地区电力负荷预测为例,所得预测结果在标准误差上提高了 29.5%,平均绝对百分误差提高了 25.7%,分析结果表明提出的模型是可行的且具有较高的精确度,为电力负荷的预测提供可靠的参考依据。

关键词:电力负荷预测;指数加权移动平均;多维数据;组合模型;时间占优

中图分类号:TM715

文献标志码:A

电力系统承担着为用户提供电能的重要作用,考虑到电力能源难以大量储存,为满足电网和用户侧日常用电量的供需平衡,这就要求电网发电量与其实际负荷大小尽可能保持一致。因此,对大量用户侧电力负荷数据进行分析、处理及预测^[1],掌握电力负荷的变化规律,为电力系统规划、安全调度和经济稳定运行提供更有效的数据支持。

多年来,国内外关于电力系统负荷预测的方法层出不穷,例如回归分析法,混沌理论,神经网络、支持向量机以及大数据下的智能预测方法^[2-8]。目前已有的预测方法虽多但均有一定局限性^[9],由于电力负荷主要受周期变化影响,其趋势波动较大,通常将过去任意时刻的数据对预测值的影响看作是相同的,预测得到的未来趋势虽满足一定精确度要求,并在应用中发挥了一定作用,但缺乏考虑一般系统的动态性。同时考虑到日常用电负荷的总体变化趋势通常表现出以年为周期的规律性,并伴随一定的随机性,因此在利用测量的实际数据整合为按一定时间周期变化的序列进行预测时往往对历史数据要求较高^[10-12]。

指数加权移动平均(exponentially weighted moving-average, EWMA)理论提出以来大多运用于运筹学、经济统计学等领域,主要是根据时间顺序对数值依次进行分配^[13-14]。文献[15-16]就是为了解决由静态数据进行分析带来的不足,通过引入 EWMA 划分不同控制限,在财务及医学领域的问题上进行了判别和预测。文献[17-18]在时间序列判别模型的基础上,提出利用 EWMA 模型对预测组合权重进行实时更新,满足模型动态性,在旅游需求及经济效益上得以应用。

本文研究在基于大量历史数据环境下的电力系统负荷预测,引入 EWMA 的理论,认为历史数据对预测值的影响程度是随着时间久远程度而递减的,即近期数据对预测值的影响大于远期数据的影响,因此在对各历史数据的权重分配上,考虑时间占优,按时间顺序进行加权,这样可以利用历史数据进行更准确的预测并有效控制预测过程中的均值漂移。

收稿日期:2019-03-12

基金项目:江西省杰出青年人才培养资助项目(20162BCB23046);江西省重点研发计划资助(20161BBH80033)

作者简介:李颖玥(1995—),女,硕士研究生,研究方向为智能电网大数据。

1 指数加权移动平均模型

指数加权移动平均(EWMA)模型^[13]为

$$Z_t = \lambda x_{t'} + (1 - \lambda) Z_{t-1} \tag{1}$$

或

$$Z_t = Z_{t-1} + \lambda (x_{t'} - Z_{t-1}) \tag{2}$$

在运用到电力负荷预测中时, $x_{t'}$ 为最近时刻 t' 的实际负荷值, 简称最近值, 一般取 $t' = t - 1$; Z_{t-1} 为前一时刻 ($t - 1$) 对应的负荷预测值; Z_t 为当前时刻 t 对应的负荷预测值。根据权重总和等于 1 的要求分别取 $x_{t'}$ 和 Z_{t-1} 的权重为 λ 和 $(1 - \lambda)$, λ 满足 $0 < \lambda < 1$ 。

式(1)或式(2)是用于本文电力负荷预测的理论基础, 该模型适用于总体趋势无明显变动的历史负荷数据。由式(1)可以看出 EMWA 模型是一个不断递推的过程, 该模型对时间顺序数据加权的特性可由式(1)扩展后得到的式(3)及图 1 进行表述。式(1)进行扩展并简化可得

$$Z_t = \lambda \sum_{j=0}^m (1 - \lambda)^j x_{t'-j} \tag{3}$$

式中, m 表示起始时刻。

上式表明 Z_t 是由 m 时刻起至当前时刻的历史数据加权平均所得的预测值, 且加权系数按时刻由近到远的顺序分别为 $\lambda, \lambda(1 - \lambda), \lambda(1 - \lambda)^2, \dots, \lambda(1 - \lambda)^j, \dots, \lambda(1 - \lambda)^m$, 即加权系数的大小随历史时刻的久远而减小, 如图 1 所示。

式(3)中系数或图 1 中权重, 在 m 趋于 ∞ 时, 满足

$$\lim_{m \rightarrow \infty} \lambda \sum_{j=0}^m (1 - \lambda)^j = \frac{\lambda}{1 - (1 - \lambda)} = 1 \tag{4}$$

一般情况下, 令权重总和都满足

$$\lambda \sum_{j=0}^m (1 - \lambda)^j \approx 1 \tag{5}$$

通过式(1)可看出 λ 大小的选择决定了在进行预测时前一时刻预测值和最近值对当前预测值的影响比重。而从式(2)来看, Z_t 则是以前一时刻预测值 Z_{t-1} 为基础并增加与最近值对应的修正值而得到的预测值, λ 是预测误差的修正系数, 具有控制作用。因此, 采用该模型进行电力负荷预测时, 既涵盖了历史过程中每一时刻的子信息, 又避免了假定限制, 在满足时间占优的要求之外又能有效控制预测过程中的均值漂移, 具备一定的合理性。

由于电力负荷具有周期性和波动性, 当波动明显时, 相应数据代入式(1)或式(2)进行预测, 极易产生滞后偏差, 为了克服这一缺点, 先考虑引入多次递推的指数加权移动平均模型, 再利用指数平滑曲线进行预测。根据电力负荷数据变化规律, 本文选用三次递推的指数加权移动平均模型, 如式(6)

$$\begin{cases} Z_t^{(1)} = \lambda x_{t'} + (1 - \lambda) Z_{t-1}^{(1)} \\ Z_t^{(2)} = \lambda Z_t^{(1)} + (1 - \lambda) Z_{t-1}^{(2)} \\ Z_t^{(3)} = \lambda Z_t^{(2)} + (1 - \lambda) Z_{t-1}^{(3)} \end{cases} \tag{6}$$

再经下列指数平滑预测模型

$$Z_t = a + b + c \tag{7}$$

式(7)是预测时刻与最近时刻间隔数为 1 的平滑曲线模型的特例, 则 Z_t 表示的是利用该模型所得的当前预测值, a, b, c 为平滑系数, 这三个系数均可由式(6)及指数加权移动平均值推导得出, 这里只给出最终推导结果如式(8)

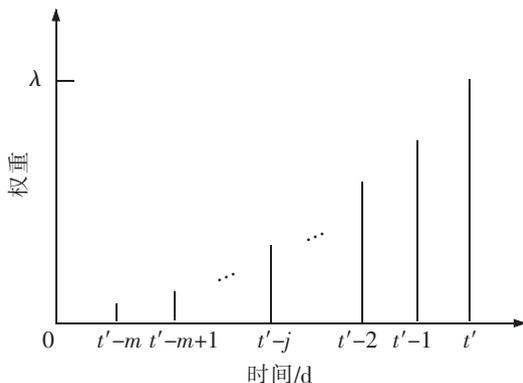


图 1 EWMA 模型
Fig.1 EWMA mode

$$\begin{cases} a=3Z_t^{(1)}-3Z_t^{(2)}+Z_t^{(3)} \\ b=\frac{\lambda}{2(1-\lambda)^2}\zeta \\ c=\frac{\lambda^2}{2(1-\lambda)^2}(Z_t^{(1)}-2Z_t^{(2)}-Z_t^{(3)}) \end{cases} \quad (8)$$

其中

$$\zeta=(6-5a)Z_t^{(1)}-2(5-4a)Z_t^{(2)}+(4-3a)Z_t^{(3)} \quad (9)$$

2 电力系统负荷预测

根据电力负荷的特点,本文将电力负荷历史数据分为同期历史数据和近期历史数据两类。同期历史数据和近期历史数据是相对的,一般情况下,同期历史数据指以年为周期的往年同月同日的负荷数据,近期历史数据指预测日期之前一个月内或者前一季度内每日的负荷数据,具体数据量可根据实际情况选择。将这两类数据看作是不同时期的单维数据,利用两类数据可分别按单维数据进行简单预测。两类数据存在远期和近期影响的局限性,因此对这两类数据相应的预测值又可进一步构成多维数据的组合预测,以获得更准确的预测结果。

2.1 单维数据的简单预测

1) 利用同期历史数据的负荷预测

对于日负荷同期历史数据的变化一般表现为无明显波动,因此可按式(1)或式(2)进行预测,则有

$$Z_{p,n,k}^h = \lambda x_{p',n,k} + (1-\lambda)Z_{p-1,n,k}^h \quad (9)$$

式中: p, n, k 分别为年、月、日; $Z_{p,n,k}^h$ 为利用同期历史数据得到的 p 年 n 月 k 日的负荷预测值; $x_{p',n,k}$ 为最近实际负荷值,即 p' 年 n 月 k 日的实际负荷值,可取 $p'=p-1$; $Z_{p-1,n,k}^h$ 为 $(p-1)$ 年 n 月 k 日的负荷预测值,此值由 $(p-1)$ 年前的同期历史数据获得。

2) 利用近期历史数据的负荷预测

由于日负荷的近期历史数据一般表现出的波动相对较大,因此可按式(6)~式(9)进行预测,则有

$$Z_{p,n,k}^r = a + b + c \quad (10)$$

式中, $Z_{p,n,k}^r$ 为利用近期历史数据得到的 p 年 n 月 k 日的负荷预测值。

2.2 多维数据的组合预测

将同期历史预测值 $Z_{p,n,k}^h$ 和近期历史预测值 $Z_{p,n,k}^r$ 当作二维数据,利用多维数据计算方法进行组合预测,可按式(1)考虑时间占优进行加权计算,则有

$$Z_{p,n,k} = \lambda Z_{p,n,k}^r + (1-\lambda)Z_{p,n,k}^h \quad (11)$$

式中, $Z_{p,n,k}$ 为 p 年 n 月 k 日的负荷预测值。

2.3 模型参数的选取

利用 EWMA 模型需要确定的初始化参数较少,主要有 2 个参数:加权系数 λ 和一次初始值 $Z_0^{(1)}$ 。

2.3.1 加权系数 λ 的选取

加权系数 λ 的选择对预测准确度的提升有着很大帮助。若参数 λ 取的越小,那么最近值 x_t 所占比重就越小,对预测误差的修正幅度就越小;反之, λ 取得越大,最近值 x_t 所占比重就越大,误差修正幅度也就越大,得到的加权系数序列 $\lambda(1-\lambda)^j$ ($j=0, 1, 2, \dots$) 的衰减速度也就会越快。因此在一定程度上, λ 也决定着参与预测的历史数据的个数。

当电力负荷数据趋于平稳无过大波动时,进行预测出现的偏差多数是由突发原因或随机因素造成的,为减少误差的修正幅度,使预测模型能包含更多历史数据的信息, λ 应取小一点,例如 0.1~0.5;当负荷数据

表现出明显波动时,预测模型应尽可能少考虑历史数据中的信息,增大修正幅度,提高模型灵敏度以便适应曲线趋势变化,此时 λ 应取得大一点,例如0.6~0.8。根据给出的基本条件和实践经验,通常情况下, λ 的取值范围一般在0.1~0.4之间。

2.3.2 一次初始值 $Z_0^{(1)}$ 的选取

EWMA模型是一个递推的过程,所以还需确定一次初始值 $Z_0^{(1)}$ 才能进行后续的预测。当历史数据较多时,初始值对后面预测结果的影响程度相对较小,即可选择实际数据的初始值作为递推的初始值;当历史数据较少时,即使是早期数据,对预测结果的影响也是较大的,此时一般可以取最初2~5期的历史数据的平均值作为初始值。

3 算例仿真及分析

3.1 算例说明

为验证本文所提预测方法的可行性,这里以某地区的电力负荷数据为例进行仿真分析,选用该地区2011年1月1日至2016年12月31日,每日00:15至24:00(每隔15分钟选用该时刻数据,即一天共选用96个时刻)的数据,利用本文提出的模型对该地区2017年1月1日至2017年5月31日每日相同时刻的负荷数据进行预测,并与实际负荷数据进行对比。

这里选取2011年至2016年全年每日00:15时刻测量出的实际负荷数据进行多项式次数为9次的曲线拟合,绘制出往年的年实际负荷数据的近似趋势对比图,如图2所示。

根据上述情况以及参数的选择条件,对2017年某月某日进行预测时的历史同期数据共6个,近期数据共30个。对参数 λ 和的初始化选取如表1。

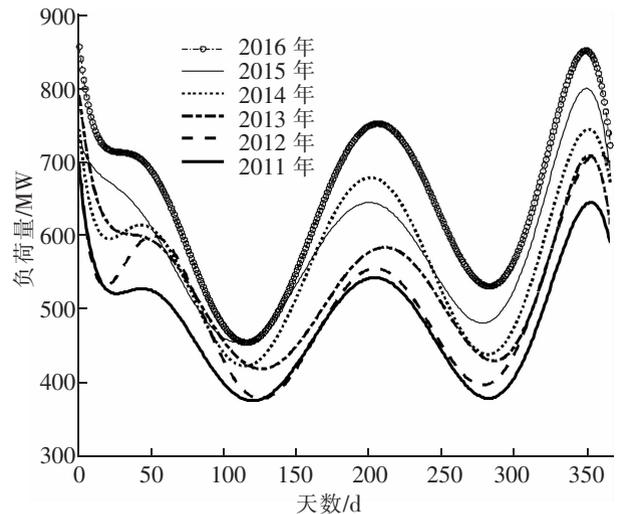


图2 2011年至2016年实际负荷数据趋势对比图
Fig.2 Comparison of actual load data trends from 2011 to 2016

表1 参数初始化选取
Tab.1 Parameter initialization selection

参数	加权系数 λ		一次初始值 $Z_0^{(1)}$	
	同期历史数据	近期历史数据	同期历史数据	近期历史数据
选择范围	[0.1~0.4]	[0.1~0.4]	前2~5期历史数据	前2~5期历史数据
初始值	0.3	0.2	前2期	前5期

3.2 预测结果

分别利用本文预测方法和传统时间序列预测法对2017年1月1日至2017年5月31日的负荷进行预测(对应00:15时刻的预测结果)。

从图3的对比图可以说明,两种预测方法得出的预测结果在整体结果走势上都与实际值保持一致,但明显可以看出,利用EMWA预测方法得出的曲线更接近于实际值,特别是在负荷波动较大处,两种预测方法精确度的差异更为明显。

为进一步验证该方法的预测效果,表2随机抽取了一些预测结果与实际值进行比较,由表中数据可见大多数预测结果与实际值相当接近,相对误差较小。

表2 负荷预测结果
Tab.2 Load forecasting results

时间	实际值/MW	预测值/MW	相对误差/%
1月1日	843.15	855.09	1.416 1
1月11日	825.35	815.07	1.245 5
1月22日	808.37	808.68	0.038 3
2月1日	623.31	582.23	6.590 6
2月11日	777.66	773.23	0.569 7
2月20日	719.51	734.76	2.119 5
3月1日	681.82	666.59	2.233 7
3月9日	713.48	720.88	1.037 2
3月20日	586.82	591.54	0.804 3
4月1日	591.16	582.92	1.393 9
4月12日	541.56	528.03	2.498 3
4月19日	519.87	528.47	1.654 3
5月1日	491.45	534.95	8.851 4
5月9日	556.26	548.06	1.294 4
5月20日	727.43	637.18	12.406 7

表3 预测评价指标参数
Tab.3 Predictive evaluation index parameters

预测方法	标准误差RMSE	平均绝对百分误差 MAPE
EWMA 模型预测	34.229 6	3.442 3%
传统方法预测	48.578 7	4.632 9%

3.3 结果分析

除了从图3可以明显看出本文预测结果更加精确之外,表3中整个月的模型预测评价指标参数也证明了本文方法对预测精密度有一定的提高,其中标准误差RMSE指标提高了29.5%,平均绝对百分误差MAPE指标提高了25.7%。

根据上述实验结果,发现预测值和实际值基本吻合,且平均误差相较其他预测模型有所降低。图4的误

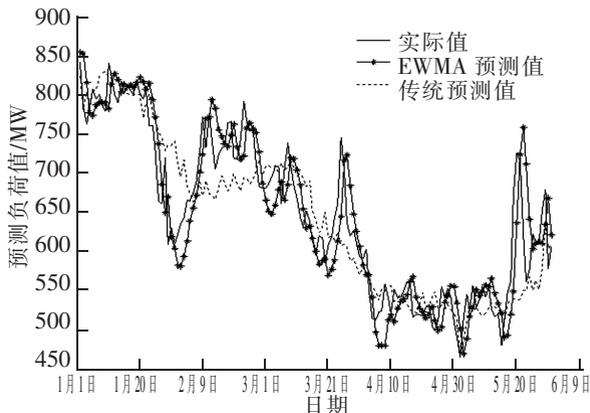


图3 不同预测方法的负荷数据预测结果对比图
Fig.3 Comparison of load data prediction results through different prediction methods

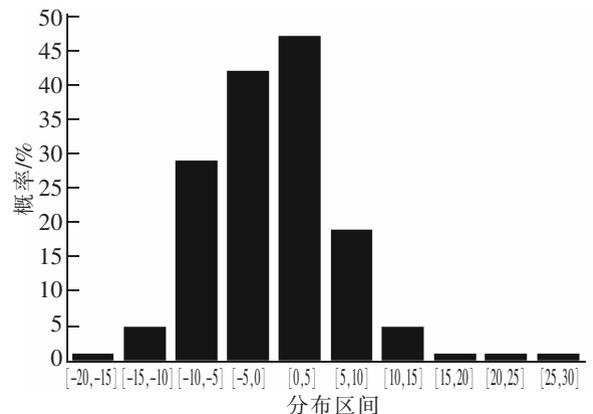


图4 预测误差分布图
Fig.4 Prediction error profile

差分布图反映了在预测结果中,有90.7%的预测结果符合预测标准,7.9%近似预测标准,仅有1.3%误差偏大的时刻,且这些点均聚集在负荷值骤升或骤降时,而导致误差偏大的原因包括了天气、空气质量以及节假日安排等,但这些都是极少数情况,这里对预测结论并无较大影响。

4 结论

本文根据电力负荷的大量历史数据,引入指数加权移动平均模型,按照时间占优对权重进行分配,研究电力负荷值的预测方法。分别给出了适用于负荷波动平稳和较大时负荷预测的一般方法,进一步分析了利用同期历史数据和近期历史数据两类数据各自作为单维数据的简单预测。考虑到两类数据对预测都存在局限性,因此结合多维数据的处理方法,利用同期历史数据的预测值和近期历史数据的预测值构成多维数据的组合预测。算例分析表明本文提出的预测模型在含有大量历史数据的背景下,对未来某时刻的电力负荷预测数据在精度上有所提高,体现了该预测模型的优越性,也验证了该模型在电力负荷预测应用中的可行性。

参考文献:

- [1] 中国电机工程学会信息化专委会. 中国电力大数据发展白皮书[S]. 北京:中国电力出版社,2013.
- [2] 张伏生,汪鸿,韩梯,等. 基于偏最小二乘回归分析的短期负荷预测[J]. 电网技术,2003,27(3):36-40.
- [3] 毛李帆,江岳春,龙瑞华,等. 基于偏最小二乘回归分析的中长期电力负荷预测[J]. 电网技术,2008,32(19):71-77.
- [4] 李东东,覃子珊,林顺富,等. 基于混沌时间序列法的微网短期负荷预测[J]. 电力系统及其自动化学报,2015,27(5):14-18.
- [5] 郑永康,陈维荣,蒋刚,等. 一种模糊支持向量的负荷混沌时间序列预测法[J]. 电力系统及其自动化学报,2007,19(6):48-52.
- [6] 刘云,张杭,张爱民. 需求侧响应下基于负荷特性的改进短期负荷预测方法[J]. 电力系统保护与控制,2018,46(13):126-133.
- [7] 王德文,孙志伟. 电力用户侧大数据分析与并行负荷预测[J]. 中国电机工程学报,2015,35(3):527-537.
- [8] 张素香,赵丙镇,王风雨,等. 海量数据下的电力负荷短期预测[J]. 中国电机工程学报,2015,35(1):37-42.
- [9] HERNANDEZ L,BALADRON C,AGUIAR J M,et al. A Survey on electric power demand forecasting:Future trends in smart grids,microgrids and smart buildings[J]. IEEE Communications Surveys & Tutorials,2014,16(3):1460-1495.
- [10] 田敏. 智能电网时序数据短期预测分析研究[D]. 保定:华北电力大学,2016.
- [11] 王志宏. 基于时间序列的电力系统短期负荷预测研究[D]. 广州:华南理工大学,2012.
- [12] 赵宏伟,任震,黄雯莹. 考虑周期性的短期负荷预测[J]. 中国电机工程学报,1997,17(3):211-213.
- [13] 阮丽雅. 基于 EWMA 模型的指数组合优化复制方法与实证研究[D]. 杭州:浙江大学,2007.
- [14] 刘轶芳,迟国泰,余方平. 基于 GARCH-EWMA 原理的期货交易保证金随动调整模型[J]. 中国管理科学,2005,13(3):6-14.
- [15] 杜军,徐建. 基于 EWMA 控制图模型的公司财务质量判别[J]. 武汉理工大学学报,2014,36(2):260-264.
- [16] 韦懿芸,华伟玉,孙亚敏,等. 基于指数加权移动平均组合模型的手足口病发病动态预测[J]. 现代预防医学,2014,41(13):2305-2308.
- [17] 陈磊,任若恩. 时间序列判别分析技术和指数加权移动平均控制图模型在公司财务危机预警中的应用[J]. 系统管理学报,2009,18(3):241-248.
- [18] 吴良平,张健. 预测组合权重更新的过程控制及分析[J]. 数理统计与管理,2017,36(6):1016-1027.

Power Load Forecasting Based on Multidimensional Combined Model of Exponential Weighted Moving Average

Li Yingyue¹, Wang Xun¹, Kang Chen², Wan Hua², Cheng Hongbo¹

(1. School of Electrical and Automation Engineering, East China Jiaotong University, Nanchang 330013, China;

2. State Grid Jiangxi Electric Power Research Institute, Nanchang 330096, China)

Abstract: With the continuous development of the power industry, the prediction of power load on the power user side has played an important part in meeting the balance between power supply and demand of users and power grid planning. Under the background of big data, in order to improve the accuracy of power load forecasting results, and in view of the influence of the time for historical data, considering the limitations in historical data of the same period and recent historical data respectively, based on the principle of time-dominant, the exponentially weighted moving-average was introduced to distribute the weight of data at different time, and an improved power load forecasting model was proposed. Taking the power load forecasting in a certain area as an example, the predicted result was improved by 29.5% in root mean squared error and the mean absolute percent error increased by 25.7%. The analysis results show that the proposed model is feasible and has high accuracy, providing a reliable reference for the power load forecasting.

Key words: power load forecasting; exponentially weighted moving average; multidimensional data; combined model; time dominance