

基于均生函数-最优子集回归模型的短期电力负荷预测方法

窦震海^{1,2}, 杨仁刚^{1*}, 焦 娇¹

(1. 中国农业大学信息与电气工程学院, 北京 100081; 2. 山东理工大学电气与电子工程学院, 淄博 255091)

摘要: 为进一步提高电力负荷预测的精度和运算速度, 针对短期负荷预测样本数据既有趋势性又有波动性的特点, 采用均生函数-最优子集回归 (mean generating function-optimal subset regression, MGF-OSR) 建立预测模型。相对于均生函数主成分回归 (mean generating function-principal component analysis, MGF-PCA) 模型, 该方法引入了一阶、二阶差分序列对高频部分进行拟合, 又建立累加生成序列拟合其趋势, 通过均值生成函数 (MGF) 将上述所有序列构建出预测因子矩阵, 采用双评分准则进行粗选, 剔除评分较低的因子, 其他预报因子经组合寻优后得到最优子集并以此建立预测模型。实例分析表明, 该模型预测的平均相对误差可低至 2.42%, 明显优于主成分回归模型的预测精度。

关键词: 电力系统, 负荷, 数学模型, 短期负荷预测, 均值生成函数, 最优子集回归

doi: 10.3969/j.issn.1002-6819.2013.14.023

中图分类号: TM714

文献标志码: A

文章编号: 1002-6819(2013)-14-0178-07

窦震海, 杨仁刚, 焦 娇. 基于均生函数-最优子集回归模型的短期电力负荷预测方法[J]. 农业工程学报, 2013, 29(14): 178—184.

Dou Zhenhai, Yang Rengang, Jiao Jiao. Method of short-term load forecasting based on mean generating function-optimal subset regression[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2013, 29(14): 178—184. (in Chinese with English abstract)

0 引言

电力负荷预测是电力系统运行过程中的一项传统研究课题^[1]。其样本序列一般采用等间隔的时间序列, 根据样本序列时间间隔的大小, 负荷预测大致分为长期预测、中期预测、短期预测以及超短期预测^[1-3]。对于各种时间尺度的样本序列, 其统计特性差别很大, 预测过程中就要相应地采用不同的预测方法和模型。因此负荷预测的核心问题就是预测的技术方法, 也就是建立预测的数学模型^[4], 对预测方法的探索, 一直是国内外学者关注的一个热点, 多年来提出了许多预测方法^[1-28]。

对于短期负荷预测, 一般以 1 d 或几天的实际值作为预测样本, 向后预测几小时或 1 d 的数据^[1], 样本数据有周期性, 但其中随机成分也较大。短期负荷预测方法主要有: 回归分析法、时间序列法、卡尔曼滤波、灰色模型、神经网络、支持向量机等^[4-28],

现有的预测模型, 如 AR (auto-regressive)、ARMA (auto-regressive and moving average model)、ARIMA (auto-regressive integrated moving average model) 和 TAR (threshold autoregressive model) 模型等, 在进行多步预测时, 预测值会趋于平均值, 且往往对极值的拟合效果欠佳。指数平滑模型和灰色模型等可以进行多步预测, 但他们表示的是一种指数增长, 对于波动性变化的序列不适用, 神经网络模型的训练过程中容易陷入局部寻优, 而且有时候不能收敛, 预测所需要的样本量也过大。

中国学者魏凤英等在 20 世纪 80 年代提出了均值生成函数 (mean generating function, MGF) 的概念, 它体现了原始时间序列样本各种长度的周期性, 并以此为基函数针对不同情况采用不同的建模方案, 既可以作多步预测, 又可以较好地预测极值, 目前其主要应用于气象预测中^[28-29], 在其他的领域应用很少。基于 MGF 的预测模型大都采用主成分分析 (principal component analysis, PCA) 模型, 该算法的主要优点是计算量小, 占用内存资源少, 但从理论和实践都已证明: 如果自变量是确定的, 得出的回归模型很可能不是最优的回归方程, 而且, 由于统计检验的显著性水平 α 的选择有任意性, 所以很难在自变量的选择、剔除过程中, 保证所选择自变量的显著性。最优子集回归模型 (optimal subset regression, OSR) 引入了两阶差分序列起到了高通

收稿日期: 2012-12-20 修订日期: 2013-06-18

基金项目: 国家高技术研究发展计划 (863 计划) (2012AA050217)

作者简介: 窦震海 (1970—), 男, 北京市房山区人, 讲师, 从事电力系统自动化等方面研究。北京 中国农业大学信息与电气工程学院, 100081。Email: douzhenhai1105@126.com

*通信作者: 杨仁刚 (1953—), 男, 教授, 博士生导师。研究领域农村电力网、农村可再生能源发电工程、电力系统自动化技术。北京 中国农业大学信息与电气工程学院, 100081。农业工程学会会员: 杨仁刚 (E041200143S)

滤波的作用, 保留了样本中的高频成分, 而对一阶差分序列均生函数的累加生成序列又对其变化趋势进行了拟合, 因此, 最优子集回归算法对序列的趋势性和波动性都可拟合, 通过粗选预报因子及回归寻优得到最优子集回归方程, 较大提高预测精度。

1 均值生成函数 (MGF)

对一个时间序列样本

$$x(t) = \{(x(1), x(2), \dots, x(n))\} \quad (1)$$

其中, n 为样本序列中的元素数量, 即样本总量, 对于式 (1) 定义其均值生成函数 (以下简称均生函数) 为

$$\bar{x}_l(i) = \frac{1}{n_l} \sum_{j=0}^{n_l-1} x(i+jl) \quad (2)$$

其中, $l=1, 2, \dots, m$; $i=1, 2, \dots, l$; $n_l=\text{INT}(n/l)$; $m=\text{INT}(n/2)$ 。

根据式 (2), 当 l 取 $1 \sim m$ 之间不同的值时, 可以得到 m 个均生函数序列

$$\begin{aligned} & \bar{x} \\ & \bar{x}_2(1), \bar{x}_2(2) \\ & \bar{x}_3(1), \bar{x}_3(2), \bar{x}_3(3) \\ & \vdots \\ & \bar{x}_m(1), \bar{x}_m(2), \dots, \bar{x}_m(m) \end{aligned}$$

由此可知, 均生函数就是将时间序列按一定的间隔取值并计算其均值而生成的。继而可以获得一个上三角矩阵

$$H_{m \times m} = \begin{bmatrix} \bar{x} & \bar{x}_2(1) & \bar{x}_3(1) & \cdots & \bar{x}_m(1) \\ \bar{x}_2(2) & \bar{x}_3(2) & \bar{x}_m(2) & & \\ \bar{x}_3(3) & \cdots & \bar{x}_m(3) & & \\ & & & \vdots & \\ & & & & \bar{x}_m(m) \end{bmatrix} \quad (3)$$

将以上矩阵按式 (4) 进行周期延拓, 构造均生函数延拓矩阵 $F_{n \times m} = (f_{ij})_{n \times m}$, 令

$$f_{ij} = f_i(t) = \bar{x}_i(t) \quad (4)$$

其中, $i=1, 2, \dots, n$; $t=i[\text{mod}(l)]$; $j=l$ 。

于是得到均生函数的延拓矩阵, 即均生函数的基本函数

$$F_{n \times m} = \begin{bmatrix} \bar{x} & \bar{x}_2(1) & \bar{x}_3(1) & \cdots & \bar{x}_m(1) \\ \bar{x} & \bar{x}_2(2) & \bar{x}_3(2) & \cdots & \bar{x}_m(2) \\ \bar{x} & \bar{x}_2(1) & \bar{x}_3(3) & \cdots & \bar{x}_m(3) \\ \bar{x} & \bar{x}_2(2) & \bar{x}_3(1) & \cdots & \vdots \\ & & & & \bar{x}_m(m) \\ \vdots & \vdots & \vdots & & \vdots \\ \bar{x} & \bar{x}_2(i_2) & \bar{x}_3(i_3) & \cdots & \bar{x}_m(i_m) \end{bmatrix} \quad (5)$$

2 最优子集回归建模

1) 生成自变量序列

为了拟合原始序列中的高频部分, 对原始序列进行两阶差分运算, 以实现高通滤波的作用。先对样本序列 $x(t)$ 进行一阶差分运算

$$\Delta x(t) = x(t+1) - x(t); \quad t=1, 2, \dots, n-1 \quad (6)$$

得到一阶差分序列

$$x^{(1)}(t) = \{\Delta x(1), \Delta x(2), \dots, \Delta x(n-1)\} \quad (7)$$

对一阶差分序列再作差分运算

$$\Delta^2 x(t) = \Delta x(t+1) - \Delta x(t); \quad t=1, 2, \dots, n-2 \quad (8)$$

得到二阶差分序列

$$x^{(2)}(t) = \{\Delta^2 x(1), \Delta^2 x(2), \dots, \Delta^2 x(n-2)\} \quad (9)$$

利用式 (2) 分别计算原始样本序列 $x(t)$, 一阶差分序列 $x^{(1)}(t)$ 和二阶差分序列 $x^{(2)}(t)$ 的均生函数, 分别记为 $\bar{x}_l^{(0)}(t)$ 、 $\bar{x}_l^{(1)}(t)$ 和 $\bar{x}_l^{(2)}(t)$ 。由式 (4) 就可以得到它们的延拓序列 $f_l^{(0)}(t)$ 、 $f_l^{(1)}(t)$ 和 $f_l^{(2)}(t)$ 。

为拟合样本序列中向上递增和向下递减的趋势^[30], 对一阶差分的均生函数序列进一步建立累加延拓序列 $f_l^{(3)}(t)$, 令其初值 $f_l^{(3)}(1)=x(1)$,

$$f_l^{(3)}(t) = x(1) + \sum_{i=1}^{t-1} f_l^{(1)}(i+1) \quad (10)$$

其中, $t=2, 3, \dots, n$; $l=1, 2, \dots, m$;

将获得约 $4m$ 个均生函数延拓序列 $f_l^{(0)}(t)$ 、 $f_l^{(1)}(t)$ 、 $f_l^{(2)}(t)$ 和 $f_l^{(3)}(t)$ ($l=1, 2, \dots, m$) 作为自变量以供选择。

2) 双评分准则 CSC (couple score criterion)

由于短期负荷样本序列中也兼有一定的趋势性, 所以采用兼顾数量评分和趋势评分的双评分准则进行自变量的筛选

$$CSC = S_1 + S_2 \quad (11)$$

其中, $S_1=nR^2$ 为数量评分, 也称精评分; R^2 为复相关系数; S_2 为趋势评分, 也称粗评分。即对当前样本相对于前一个样本的变化趋势的评价, 一般将趋势升、平、降 3 类, 对样本 $x(t)$ 和拟合值 $f(t)$ ($t=1, 2, \dots, n$) 进行差分得到 $\Delta x(t)$ 和 $\Delta f(t)$ ($t=1, 2, \dots, n-1$), 然后各自求均值

$$\begin{cases} U = \frac{1}{n-1} \sum_{t=1}^{n-1} |\Delta x(t)| \\ V = \frac{1}{n-1} \sum_{t=1}^{n-1} |\Delta f(t)| \end{cases}$$

其评价的趋势变化量分 3 类, 按式 (12) 得到 T_x , 并参照式 (12) 得到 T_f

$$T_x(t) = \begin{cases} T_A & \Delta x_t > U \\ T_B & |\Delta x_t| \leq U \\ T_C & \Delta x_t < -U \end{cases} \quad (12)$$

建立一个 $n_{3 \times 3}$ 的列联表矩阵, 行列标号都分别对应上述 A、B、C 3 种趋势, 在所有的 t 时刻比较 2 个序列趋势 T_x 、 T_f 相同的情况, 计入矩阵中相应的元素并进行累加, n_{ij} 的值即为样本值和预报值的趋势情况出现的频数。

继而趋势评分

$$S_2 = 2[R_1 + (n-1)\ln(n-1) - R_2 - R_3] \quad (13)$$

其中, $R_1 = \sum_{i=1}^I \sum_{j=1}^I n_{ij} \ln n_{ij}$, $I = 3$ 为趋势类别数;

$$R_2 = \sum_{i=1}^I n_{i.} \ln n_{i.}, \quad n_{i.} = \sum_{j=1}^I n_{ij}; \quad R_3 = \sum_{j=1}^I n_{.j} \ln n_{.j},$$

$$n_{.j} = \sum_{i=1}^I n_{ij}.$$

3) 粗选预测因子

由于引入了差分序列、累加序列及其均生函数序列, 如果将所有均生函数序列都作为自变量组合建立子集, 其计算量过大, 也没有必要。于是先通过 CSC 值筛选, 剔除 CSC 值较低的预报因子。

建立每一个延拓序列与原始样本序列之间的一元回归, 计算其双评分准则 CSC 值, 并进行 χ^2 检验, 确定显著性水平 α , 凡 $CSC > \chi^2_\alpha$ 的序列粗选为预报因子, 将入选的预报因子数量记为 p 。这样就确定了 p 个自变量, 由二项式定理, 共有 2^p-1 种组合, 每个组合作为一个子集。

4) 将所有粗选出来的预报因子组合形成的 2^p-1 个子集对原始样本序列进行回归计算, 并再次计算所有回归结果的双评分准则 CSC 值, 并选择 CSC 值最大的子集——最优子集作为预报方程。

5) 如果最优子集由 k 个自变量构成, 则其均生函数—最优子集回归模型为

$$\hat{x}(t) = a_0 + \sum_{i=1}^k a_i f_i(t) \quad (14)$$

若作 q 步预报, 将上述 $f_i(t)$ ($i=1, 2, \dots, k$) 按式 (4) 再进行 q 步延拓, 代入式 (14) 即可。

均生函数最优子集回归模型建模的流程图见图 1。

3 算例分析

本文采取了 2010 年 12 月份北方某地区 1 d 的整点负荷值, 采用上述均生函数—最优子集回归算法进行其后 4 h 整点负荷值的预测, 具体过程如下:

可知样本容量 $n=24$, 取 $m=\text{INT}(n/2)=12$, 由式 (2) 得到该样本序列的均生函数 $f_l^{(0)}(t)$, 进而计算其一阶、二阶差分序列, 并得到一阶、二阶差分序列的均生函数 $f_l^{(1)}(t)$ 和 $f_l^{(2)}(t)$, 利用式 (4) 得到 3 个序列的延拓序列, 再由式 (10) 得到累加延拓序

列 $f_l^{(3)}(t)$, 这样共得到 45 个预报因子。

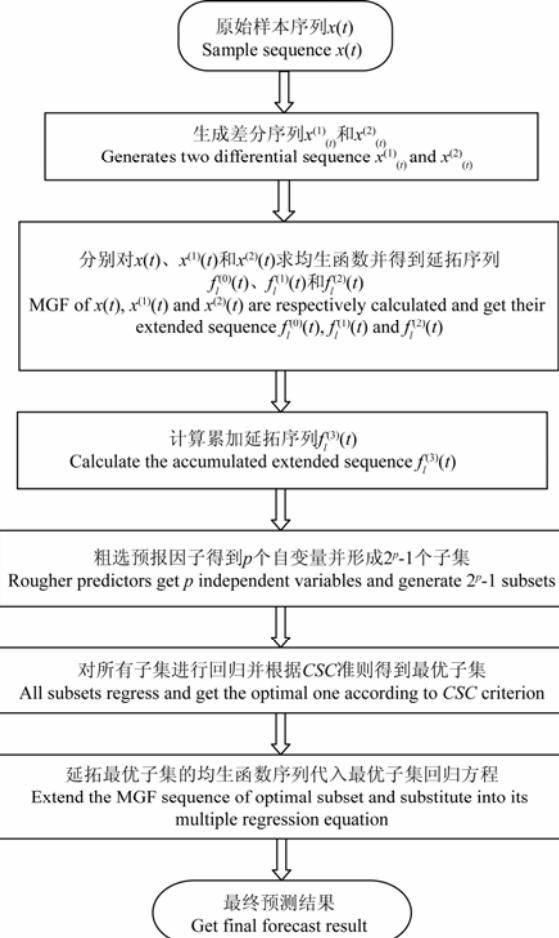


图 1 MGF-OSR 模型的建模预测流程图

Fig.1 Flow diagram of modeling and forecast by MGF-OSR

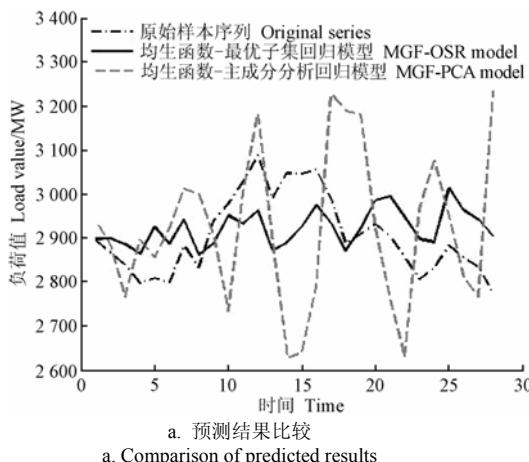
对上述 45 个预报因子与样本序列进行一元回归计算, 并对回归序列求其双评分值。进行 χ^2 检验, 给定显著性水平 $\alpha=0.05$, 由于 $CSC=S_1+S_2$, 且 S_1 、 S_2 均满足 χ^2 分布, 由于采用的是一元回归, 所以 S_1 的自由度 $v_1=1$, 对 S_2 有 $v_2=(3-1)\times(3-1)=4$, 故 CSC 的总自由度 $v=5$, 查表得 $\chi^2_{0.05}(5)=11.07$, 筛选出 8 个预报因子。

这样共得到 $2^8-1=255$ 个子集, 对这 255 个子集进行回归计算, 并再次对所有子集的回归进行双评分计算, 不同自变量个数的最优子集组合及其复相关系数 R^2 和 CSC 值见表 1, 取其中 CSC 值最大的子集即为最优子集。最后利用该子集建立回归方程

$$\begin{aligned} \hat{x}(t) = & 260.61 + 1.8769 f_5^{(0)}(t) + \\ & 0.5976 f_{10}^{(0)}(t) + 1.4563 f_5^{(1)}(t) - \\ & 0.5884 f_9^{(1)}(t) + 0.222 f_{10}^{(1)}(t) - \\ & 0.0109 f_5^{(2)}(t) - 1.597 f_5^{(3)}(t) \end{aligned} \quad (15)$$

由式(4)对各均生函数序列进行 $k=4$ 步延拓后, 代入式(15)即可得到相应的预测值。

计算结果及相关误差曲线如图2所示, 由图2a可以看出, MGF-PCA 模型对于样本数据波动方向的拟合相对来说比较准确, 但由图 2b 看出, MGF-PCA 模型拟合数据的误差明显高于 MGF-OSR 模型, 由表 2 得到 2 种模型对样本数据拟合的最大误差相差 8%以上, 平均拟合误差也相差 3%以上, 对于预测结果, 由表 3 得到 MGF-PCA 模型的平均预测误差比 MGF-OSR 模型高 1.5%, 这是由于 MGF- OSR 模型引入了二阶差分序列, 有效地拟合了原始序列中的高频成分, 大大降低了拟合和预测的误差, 在本文算例中, 最终确定的最优子集回归方程里, 包含了 3 个一阶差分序列、1 个二



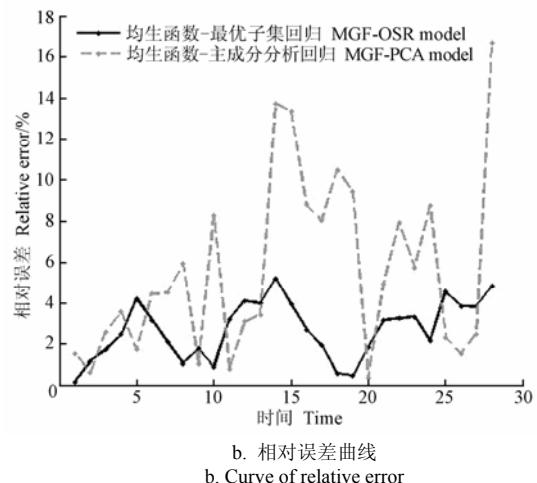
a. 预测结果比较
a. Comparison of predicted results

阶差分序列和 1 个累加序列的均生函数序列。

表 1 不同自变量个数 k 的最优子集及其参数

Table 1 Optimal subset and its parameters of number k of different independent variables

k	最优子集 Optimal subset	R^2	双评分值 CSC value
1	$f_5^{(1)}(t)$	0.03931	18.305
2	$f_5^{(0)}(t), f_9^{(0)}(t)$	0.14106	24.727
3	$f_{10}^{(0)}(t), f_5^{(1)}(t), f_{10}^{(1)}(t)$	0.13622	30.542
4	$f_9^{(0)}(t), f_{10}^{(0)}(t), f_5^{(1)}(t), f_9^{(1)}(t)$	0.1439	30.719
5	$f_9^{(0)}(t), f_{10}^{(0)}(t), f_9^{(1)}(t), f_{10}^{(1)}(t), f_5^{(2)}(t)$	0.14384	30.717
6	$f_5^{(0)}(t), f_{10}^{(0)}(t), f_5^{(1)}(t), f_9^{(1)}(t), f_{10}^{(1)}(t), f_5^{(3)}(t)$	0.18037	31.321
7	$f_5^{(0)}(t), f_{10}^{(0)}(t), f_5^{(1)}(t), f_9^{(1)}(t), f_{10}^{(1)}(t), f_5^{(2)}(t), f_5^{(3)}(t)$	0.18037	31.322
8	$f_5^{(0)}(t), f_9^{(0)}(t), f_{10}^{(0)}(t), f_5^{(1)}(t), f_9^{(1)}(t), f_{10}^{(1)}(t), f_5^{(2)}(t), f_5^{(3)}(t)$	0.2006	20.638



b. 相对误差曲线

b. Curve of relative error

图 2 2 种模型的预测结果及相对误差比较
Fig 2. Comparison of predicted results and relative error by two models

表 2 拟合样本数据相对误差比较

Table 2 Relative error of fitting sample series

模型 Model	最大拟合误差 Maximum fitting error/%	最小拟合误差 Minimum fitting error/%	平均拟合误差 Average fitting error/%
均生函数-最优子集回归 MGF-OSR	5.16	0.13	2.41
均生函数-主成分分析回归 MGF-PCA	13.73	0.35	5.53

表 3 负荷预测结果比较

Table 3 Comparison of load forecast result

预测时间点 Time point	实际负荷值 Measured value of load/MW	最优子集回归 MGF-OSR			主成分分析回归 MGF-PCA		
		预测值 Forecast value /MW	预测误差 Forecast error/%	平均相对误差 Average relative error/%	预测值 Forecast value /MW	预测误差 Forecast error/%	平均相对误差 Average relative error/%
1	2883	3013.8	4.5357		2949.0	2.2893	
2	2854	2963.4	3.8334		2810.5	1.5248	
3	2834	2941.6	3.7964	4.2394	2764.3	2.4600	5.7375
4	2772	2904.8	4.7920		3234.3	16.676	

需要指出的是, MGF-OSR 模型由于其本身生成了近乎 4 倍于 MGF-PSA 模型的均生函数序列, 并经过 2 次一元回归筛选, 计算量要大于 MGF-PSA 模型, 但在计算机技术高度发达的今天, 计算量完全能够承受, 在本文算例的仿真计算过程中两者的

运算时间没有明显差异。

4 结论

本文尝试将 MGF-OSR (均生函数-最优子集回归算法) 应用于电力系统短期负荷预测中, 最优子

集回归模型对原始样本序列进行周期性延拓作为回归预报因子备选，充分考虑了短期负荷数据的周期性变化，对样本序列的差分变换保留了数据的高频信息，而累加生成序列又对其变化趋势进行了拟合，所以均生函数最优子集回归模型对于短期负荷预测有很大的实用价值，经实例验证预测最大误差降低了10%。

由于该模型中只有数学和统计学手法进行运算，没有结合对电力负荷同样有影响的其他影响因素，比如天气、日期类型、政策调整因素等等，但上述影响因素的惯性较大，对于短期电力负荷预测来说，可以忽略这些因素的影响，所以该模型较适合用于短期负荷预测，对于中长期预测的结果很可能会有较大的误差。

[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, 28(17): 1–11.
Kang Chongqing, Xia Qing, Zhang Boming. Review of power system load forecasting and its development[J]. Automation of Electric Power Systems, 2004, 28(17): 1–11. (in Chinese with English abstract)
- [2] 牛东晓, 曹树华, 赵磊, 等. 电力负荷预测技术及其应用[M]. 北京: 中国电力出版社, 1998: 165–196.
- [3] Campbell P R J, Adamson K. Methodologies for load forecasting[C]// 2006 3rd International IEEE Conference on Intelligent Systems, London, 2006: 800–806.
- [4] James W Taylor. Short-term load forecasting with exponentially weighted methods[J]. IEEE Transactions On Power Systems, 2012, 27(1): 458–464.
- [5] 霍利民, 尹金良, 樊云飞, 等. 基于改进GEP的农网短期负荷预测[J]. 农业工程学报, 2009, 25(10): 193–197.
Huo Limin, Yin Jinliang, Fan Yunfei, et al. Short-term load forecasting of countryside distribution network based on improved gene expression programming[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2009, 25(10): 193–197. (in Chinese with English abstract)
- [6] 李丽, 叶林. 基于改进持续法的短期风电功率预测[J]. 农业工程学报, 2010, 26(12): 182–187.
Li Li, Ye Lin. Short-term wind power forecasting based on an improved persistence approach[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2010, 26(12): 182–187. (in Chinese with English abstract)
- [7] 陈博, 欧阳竹. 基于BP神经网络的冬小麦耗水预测[J]. 农业工程学报, 2010, 26(4): 81–86.
Chen Bo, Ouyang Zhu. Prediction of winter wheat evapotranspiration based on BP neural networks[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2010, 26(4): 81–86. (in Chinese with English abstract)
- [8] 毛李帆, 江岳春, 姚建刚, 等. 采用正交信号修正法与偏最小二乘回归的中长期负荷预测[J]. 中国电机工程学报, 2009, 29(16): 82–88.
- [9] 陆宁, 武本令, 刘颖. 基于自适应粒子群优化的SVM模型在负荷预测中的应用[J]. 电力系统保护与控制, 2011, 39(15): 43–46, 51.
Lu Ning, Wu Benling, Liu Ying. Application of support vector machine model in load forecasting based on adaptive particle swarm optimization[J]. Power System Protection and Control, 2011, 39(15): 43–46, 51. (in Chinese with English abstract)
- [10] 李伟, 董伟栋, 袁亚南. 基于组合函数和遗传算法最优化离散灰色模型的电力负荷预测[J]. 电力自动化设备, 2012, 32(4): 76–79.
Li Wei, Dong Weidong, Yuan Yanan. Load forecasting based on discrete grey model optimized by composite function and genetic algorithm[J]. Electric Power Automation Equipment, 2012, 32(4): 76–79. (in Chinese with English abstract)
- [11] 马瑞, 姜飞, Huang G M. 基于电力系统负荷变动速率的美国得州ERCOT短期负荷预测[J]. 电力自动化设备, 2012, 32(2): 81–84.
Ma Rui, Jiang Fei, Huang G M. Short-term load forecasting based on load fluctuation rate[J]. Electric Power Automation Equipment, 2012, 32(2): 81–84. (in Chinese with English abstract)
- [12] 万昆, 柳瑞禹. 区间时间序列向量自回归模型在短期电力负荷预测中的应用[J]. 电网技术, 2013, 36(11): 77–81.
Wan Kun, Liu Ruiyu. Application of interval time-series vector autoregressive model in short-term load forecasting[J]. Power System Technology, 2013, 36(11): 77–81. (in Chinese with English abstract)
- [13] 张平, 潘学萍, 薛文超. 基于小波分解模糊灰色聚类和BP神经网络的短期负荷预测[J]. 电力自动化设备, 2012, 32(11): 121–125+141.
Zhang Ping, Pan Xueping, Xue Wenchao. Short-term load forecasting based on wavelet decomposition, fuzzy gray correlation clustering and BP neural network[J]. Electric Power Automation Equipment, 2012, 32(11): 121–125+141. (in Chinese with English abstract)
- [14] 周德强. 基于最小一乘法的GM(1,1)模型及在负荷预测中的应用[J]. 电力系统保护与控制, 2011, 39(1): 100–103.
Zhou Deqiang. GM(1,1) model based on least absolute deviation and its application in the power load forecasting[J]. Power System Protection and Control, 2011, 39(1): 100–103. (in Chinese with English abstract)
- [15] 耿艳, 韩学山, 韩力. 基于最小二乘支持向量机的短期负荷预测[J]. 电网技术, 2008, 32(18): 72–76.
Geng Yan, Han Xueshan, Han Li. Short-term load forecasting based on least squares support vector machines[J]. Power System Technology, 2008, 32(18): 72–76. (in Chinese with English abstract)

- [16] 陈昊. 基于不对称自回归条件异方差模型的短期负荷预测[J]. 电网技术, 2008, 32(15): 84—89.
Chen Hao. Short-term load forecasting based on asymmetric autoregressive conditional heteroscedasticity models[J]. Power System Technology, 2008, 32(15): 83—89. (in Chinese with English abstract)
- [17] 罗玮, 严正. 基于广义学习矢量量化和支持向量机的混合短期负荷预测方法[J]. 电网技术, 2008, 32(13): 62—68.
Luo Wei, Yan Zheng. A hybrid approach of short-term load forecasting based on generalized learning vector quantity and support machine vector[J]. Power System Technology, 2008, 32(13): 62—68. (in Chinese with English abstract)
- [18] 张思远, 何光宇, 梅生伟, 等. 基于相似时间序列检索的超短期负荷预测[J]. 电网技术, 2008, 32(12): 56—59.
Zhang Siyuan, He Guangyu, Mei Shengwei, et al. Ultra-short term load forecasting based on similarity search in time-series[J]. Power System Technology, 2008, 32(12): 56—59. (in Chinese with English abstract)
- [19] 王德意, 杨卓, 杨国清. 基于负荷混沌特性和最小二乘支持向量机的短期负荷预测[J]. 电网技术, 2008, 32(7): 66—71.
Wang Deyi, Yang Zhuo, Yang Guoqing. Short-term load forecasting based on chaotic characteristic of loads and least squares support vector machines[J]. Power System Technology, 2008, 32(7): 66—71. (in Chinese with English abstract)
- [20] 方仍存, 周建中, 彭兵, 等. 电力负荷混沌动力特性及其短期预测[J]. 电网技术, 2008, 32(4): 61—66.
Fang Rengcun, Zhou Jianzhong, Peng Bing, et al. Chaotic dynamics of power load and its short-term forecasting[J]. Power System Technology, 2008, 32(4): 61—66. (in Chinese with English abstract)
- [21] 罗滇生, 何洪英. 基于形态相似准则的曲线拟合算法及其在超短期负荷预测中的应用[J]. 电网技术, 2007, 31(21): 81—84.
Luo Diansheng, He Hongying. A shape similarity criterion based curve fitting algorithm and its application in ultra-short-term load forecasting[J]. Power System Technology, 2007, 31(21): 81—84. (in Chinese with English abstract)
- [22] 金义雄, 段建民, 徐进, 等. 考虑气象因素的相似聚类短期负荷组合预测方法[J]. 电网技术, 2007, 31(19): 60—64, 82.
Jin Yixiong, Duan Jianmin, Xu Jin, et al. A combinational short-term load forecasting method by use of similarity clustering and considering weather factors[J]. Power System Technology, 2007, 31(19): 60—64, 82. (in Chinese with English abstract)
- [23] 李伟, 袁亚南, 牛东晓. 基于缓冲算子和时间响应函数优化灰色模型的中长期负荷预测[J]. 电力系统保护与控制, 2011, 39(10): 59—63.
Li Wei, Yuan Yanan, Niu Dongxiao. Long and medium term load forecasting based on grey model optimized by buffer operator and time response function[J]. Power System Protection and Control, 2011, 39(10): 59—63. (in Chinese with English abstract)
- [24] 陆宁, 周建中, 何耀耀. 粒子群优化的神经网络模型在短期负荷预测中的应用[J]. 电力系统保护与控制, 2010, 38(12): 65—68.
Lu Ning, Zhou Jianzhong, He Yaoyao. Particle swarm optimization-based neural network model for short-term load forecasting[J]. Power System Protection and Control, 2010, 38(12): 65—68. (in Chinese with English abstract)
- [25] 葛少云, 贾鸥莎, 刘洪. 基于遗传灰色神经网络模型的实时电价条件下短期电力负荷预测[J]. 电网技术, 2012, 36(1): 224—229.
Ge Shaoyun, Jia Ousha, Liu Hong. A gray neural network model improved by genetic algorithm for short-term load forecasting in price-sensitive environment[J]. Power System Technology Jan, 2012, 36(1): 224—229. (in Chinese with English abstract)
- [26] 李瑾, 刘金朋, 王建军. 采用支持向量机和模拟退火算法的中长期负荷预测方法[J]. 中国电机工程学报, 2011, 31(16): 63—66.
Li Jin, Liu Jinpeng, Wang Jianjun. Mid-long term load forecasting based on simulated annealing and SVM algorithm[J]. Proceedings of the Chinese Society For Electrical Engineering, 2011, 31(16): 63—66. (in Chinese with English abstract)
- [27] 黄银华, 彭建春, 李常春, 等. 马尔科夫理论在中长期负荷预测中的应用[J]. 电力系统及其自动化学报, 2011, 23(5): 131—136.
Huang Yinhua, Peng Jianchun, Li Changchun, et al. Application of markov theory in mid-long term load forecasting[J]. Proceedings of the Chinese Society of Universities for Electric Power System and Automation, 2011, 23(5): 131—136. (in Chinese with English abstract)
- [28] 穆钢, 郭鹏伟, 肖白, 等. 基于灰色均生函数模型的电力系统月度负荷预测[J]. 东北电力大学学报, 2011, 31(3): 1—6.
Mu Gang, Guo Pengwei, Xiao Bai, et al. A power system monthly load forecasting method based on the model of grey-mean generating function[J]. Journal of Northeast Dianli University, 2011, 31(3): 1—6. (in Chinese with English abstract)
- [29] 窦浩洋, 邓航, 孙小明, 等. 基于均生函数-最优子集回归预测模型的青藏高原气温和降水短期预测[J]. 北京大学学报: 自然科学版, 2010, 46(4): 643—648.
Dou Haoyang, Deng Hang, Sun Xiaoming, et al. Short-term temperature and precipitation forecast over Tibetan Plateau using mean generating function-optimal subset regression[J]. Acta Scientiarum Naturalium Universitatis Pekinensis, 2010, 46(4): 643—648. (in Chinese with English abstract)
- [30] 张德宽, 杨贤为, 邹旭恺. 均生函数—最优子集回归在高温极值预测中的应用[J]. 气象, 2003, 29(4): 44—47.
Zhang Dekuan, Yang Xianwei, Zou Xukai. Application of mean generating function-optimal subset regression to the prediction of high temperature extremes[J]. Meteorological Monthly, 2003, 29(4): 44—47. (in Chinese with English abstract)
- [31] 魏凤英. 现代气候统计诊断与预测技术[M]. 北京: 气象出版社, 2007, 239—265.

Method of short-term load forecasting based on mean generating function-optimal subset regression

Dou Zhenhai^{1,2}, Yang Rengang^{1*}, Jiao Jiao¹

(1. College of Information and Electrical Engineering, China Agricultural University, Beijing, 100081, China; 2. School of Electrical and Electronic Engineering, Shandong University of Technology, Zibo, 255091, China)

Abstract: Power load forecasting can be divided into long-term prediction, medium-term prediction, short-term prediction and ultra short-term prediction, according to different time horizons of sample sequences. If sample sequences are different, their statistical characteristics are different. Therefore, we should adopt different forecast methods and models in this prediction process. This paper mainly discusses short-term load forecasting. Power system short-term load sample sequences not only have the characteristics of tendency and periodicity, but it also fluctuates greatly, making it difficult to forecast. In the current forecast models, there are some drawbacks, and the accuracy of fitting is not good. In order to improve the accuracy of short-term prediction, this paper established the Optimal Subset Regression (OSR) model for prediction based on the Mean Generating Function (MGF) sequence. MGF adopts m ($m=INT(n/2)$) different cycles to extract sample data from the original sample sequence, and $x(n)$ to calculate their averages to get the new sequence. Then they are repeatedly extended to the length of the original sample sequence and we can get $n \times m$ matrix $F_{n \times m}$ called Mean Generating Function matrix. Each column vector $f_l^{(0)}(t)$ of $F_{n \times m}$ can be used as a regression predictor of the original sample sequence. Furthermore, in order to fit the high frequency component of the original sample sequence, we make twice-differencing operations of original sample sequences so that we can achieve the effect of high-pass filtering. The first-order difference sequence of $x(n)$ is $x^{(1)}(n-1)$ and the second-order difference sequence is $x^{(2)}(n-2)$. We can get $f_l^{(1)}(t)$ and $f_l^{(2)}(t)$ by calculating the MGF extended sequence of $x^{(1)}(n-1)$ and $x^{(2)}(n-2)$ respectively, then generating accumulation extended sequence $f_l^{(3)}(t)$ by using $f_l^{(1)}(t)$, so we can get about $4m$ MGF extended sequence $f_l^{(0)}(t)$, $f_l^{(1)}(t)$, $f_l^{(2)}(t)$ and $f_l^{(3)}(t)$ ($l=1, 2, \dots, m$). In order to reduce the calculation work, we use all the predictors for roughing, using the sample sequence for simple regression. According to the couple score criterion (CSC), we can get the CSC value of simple regression. Then we make χ^2 test and keep qualified predictors, which, with bigger CSC values, are about 1/6 of the original predictors. We take these qualified predictors for free combination, generating 2^p-1 subsets, and using these subsets for regression calculation. Then we calculate again the CSC value of the regression result, and select the subset with the maximum CSC value—the optimal subset using as prediction regression equation. According to the requirements of the prediction length, we extend the length of predictive factors of the optimal subset, substituting the extension value into the regression equation, so we can get the forecast results.

This paper takes a certain area in northern China as an example and uses hourly load values as the sample sequence, using the above algorithm to forecast four-hour-ahead load values. In this case, we got a total of 45 predictors, then 8 predictors by roughing, and generated 255 subsets. By regression calculation, we determined the optimal subset regression equation. By using the equation, we calculated the fitting value average error at 2.41%. According to the above method extending predictors, we identified the prediction value by regression calculation. The prediction average error is only 4.24%. Compared with principal component analysis of mean generating function model and grey model, the maximum error of prediction model was reduced by 10% or so.

Key words: electric power systems, loads, mathematical models, short-term load forecasting, mean generating function(MGF), optimal subset regression(OSR)

(责任编辑: 张俊芳)