

基于 WHAC-E 组合预测模型的短期电力负荷预测

苏士美<sup>1</sup>, 王明霞<sup>1</sup>, 姚 猛<sup>2</sup>, 张建华<sup>1</sup>

(1. 郑州大学 电气工程学院, 河南 郑州 450001; 2. 河南省新乡市供电公司, 河南 新乡 453000)

摘 要: 首先选用回归滑动平均、神经网络模型、支持向量机模型和粒子群优化支持向量机模型 4 种单一模型进行预测分析; 然后利用运筹学中非最优的组合预测思想, 选线性组合、加权几何平均组合和加权调和平均组合 3 种组合模型及等权法、简单加权平均法、均方误差倒数法和熵值法 4 种组合模型权重求解方法; 通过某电力公司原始负荷记录数据及实时气象数据对其三日负荷进行预测, 算例分析验证了所提出的组合预测模型应用在短期电力负荷中具有有效性和精确性, 能够为短期电力负荷预测提供一定的借鉴。

关键词: 负荷预测; 单一预测模型; 熵值法; 加权调和平均; 组合预测

中图分类号: TM715 文献标志码: A doi:10.3969/j.issn.1671-6833.2014.03.021

0 引言

负荷预测是电力系统进行规划和设计的基础, 如何提高预测有效性和精度一直是负荷预测领域的研究热点. 回归滑动平均 (ARMA) 模型<sup>[1]</sup>、神经网络 (BP) 模型<sup>[2]</sup>、支持向量机 (SVM) 模型<sup>[3]</sup> 等几种单一预测模型在短期负荷预测中得到了广泛的应用. 现阶段, 已证明组合预测模型一般比单一预测模型的预测精度高. 笔者在此基础上, 将证券组合模型的原理应用在短期电力负荷预测中, 即是将单一预测模型通过信息融合并且赋予不同权重的方法建立组合预测模型. 组合模型的研究方向主要有两种, 一是将学习优化算法与传统的单一预测模型进行组合; 二是将多个单一模型的预测结果进行加权组合<sup>[4]</sup>, 根据各单一模型在历史数据中的表现确定其组合权重. 文献 [5] 通过神经网络自适应地调整各种预测模型的权重, 该方法由于神经网络易陷入局部极小值和网络隐含层神经元个数的选择影响, 网络拟合权重的结果最优与否不能准确判定.

笔者首先对 4 种单一模型的预测效果进行分析, 剔除预测效果最差的一种单一模型; 再将证券预测组合模型 (3 种模型和 4 种权重求解方法) 应用在短期电力负荷之中, 通过算例提出 12 组组

合预测模型, 分析得出预测效果最好的组合模型.

1 基于 WHAC-E 的组合预测

1.1 加权调和平均组合模型原理

设  $k$  种单一预测模型, 预测结果分别用  $f_1, f_2, \dots, f_k$  表示,  $j$  为权重求解方法的编号 ( $j=1, 2, 3, 4$ ), 第  $i$  个单一模型的预测效果赋予其在组合模型中的权重为  $w_{ji}$ . 笔者首次提出将证券组合模型的加权调和平均组合 (WHAC) 模型用于电力负荷预测中, 利用运筹学中非最优的组合预测思想, 结合下列 WHAC 组合模型.

$$F_{1j} = 1 / \sum_{i=1}^k \frac{w_{ji}}{f_i} \tag{1}$$

式中, 只需求解出  $w_{ji}$ , 即可得到组合预测模型,  $F_{1j}$  表示组合 WHAC 组合预测模型结果.

为了验证实验效果, 笔者给出其他两种组合模型, 即是加权几何平均组合 (WGMC) 模型和线性组合 (LC) 模型.

$$F_{2j} = \sum_{i=1}^k w_{ji} f_i; \tag{2}$$

$$F_{3j} = \prod_{i=1}^k f_i^{w_{ji}}. \tag{3}$$

式中:  $F_{2j}, F_{3j}$  分别代表 LC 模型和 WGMC 模型组合预测模型结果.

收稿日期:2013-11-07; 修订日期:2013-12-11  
基金项目:河南省自然科学研究计划项目(2011A510022)  
作者简介:苏士美(1965-),女,河南永城人,郑州大学副教授,研究方向为信号检测与处理,Email:smsu@zzu.edu.cn.

1.2 熵值法 (Entropy,E) 原理

步骤 1:计算第  $i$  种单一预测方法在  $t$  时刻的预测绝对误差  $e_{it}$ ;

$$e_{it} = |(x_t - x_{it})/x_t|. \tag{4}$$

式中,  $x_t$  ( $t = 1, 2, \dots, N; N = 72$ ) 代表预测对象样本,  $x_{it}$  为第  $i$  种单一预测模型在第  $t$  时刻的预测结果.

步骤 2:归一化处理单一预测模型预测的相对误差序列,计算第  $i$  种单一预测模型在第  $t$  时刻的预测结果的相对误差比重  $p_{it}$  如下:

$$p_{it} = \frac{e_{it}}{\sum_{t=1}^N e_{it}}. \tag{5}$$

步骤 3:计算第  $i$  种单一预测模型在  $t$  时刻的预测结果的相对误差的熵值  $h_i$ ;

$$h_i = -u \sum_{t=1}^N p_{it} \ln p_{it}. \tag{6}$$

其中,  $u > 0$  且为常数,  $\ln$  为自然对数,取  $0 \leq h_i \leq 1, u = 1/\ln N$ .

步骤 4:计算第  $i$  种单一预测模型的绝对误差序列的变异度系数  $d_i$ .

$$d_i = 1 - h_i. \tag{7}$$

步骤 5:计算某单一预测模型所预测结果的权重  $w_{4i}$ :

$$w_{4i} = \frac{1}{k-1} \left( 1 - \frac{d_i}{\sum_{i=1}^k d_i} \right). \tag{8}$$

同时给出等权法 (EW)、简单加权平均法 (SWA)、均方误差倒数法 (MSEC) 3 种权重求解方法求解公式,如 (9) ~ (11) 所示:

$$w_{1i} = \frac{1}{k}. \tag{9}$$

$$w_{2i} = \frac{E_{ii}^{-\frac{1}{2}}}{\sum_{i=1}^k E_{ii}^{-\frac{1}{2}}}, i = 1, 2, \dots, k. \tag{10}$$

$$w_{3i} = \frac{2i}{k(k+1)}, i = 1, 2, \dots, k. \tag{11}$$

在公式 (10) 中,  $E_{ii} = \sum_{t=1}^N (x_t - x_{it})^2$ , 在以上所有求权重的公式中满足:  $\sum_{i=1}^k w_{ji} = 1, w_i \geq 0, i = 1, 2, \dots, k$ .

1.3 预测评价体系

在此基础上利用预测模型的平均绝对百分比误差 (MAPE) 和均方误差 (MSE) 来评价各个模型的表现.

$$MAPE = \frac{1}{N} \sum_{t=1}^N \left| \frac{\hat{y}_t - y_t}{y_t} \right|; \tag{12}$$

$$MSE = \frac{1}{N} \sum_{t=1}^N (\hat{y}_t - y_t)^2. \tag{13}$$

式中:  $y_t$  表示训练样本,  $\hat{y}_t$  表示模型预测后的预测结果. 图 1 为组合预测模型的流程图.

2 单一预测模型选择

ARMA 模型是随机时间序列模型且短期负荷预测精度较高的模型;BP 模型是带有隐含层的反馈型神经网络,经过优化的 BP 网络在短期负荷预测中得到了广泛的应用;SVM 模型是在小样本、结构风险最小化等特性的前提下,降低了计算的复杂性,加快了求解的速度,在负荷预测领域大量使用.

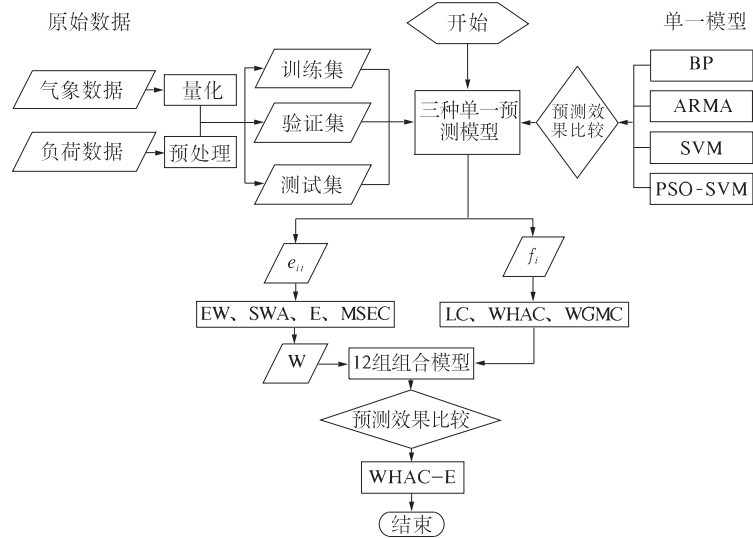


图 1 组合模型流程图  
Fig.1 Combination model flowchart

结合负荷的特点,本文经典预测方法首选 ARMA 模型、智能预测方法选择优化的 BP 模型和 SVM 模型. 为了优化 SVM 的惩罚参数和核参数,利用 SVMcgForgress( ) 函数和 PSO 寻优 SVM 的参数,分别建立了 SVM 模型和粒子群优化支持向量机(PSO-SVM)模型.

3 算例分析

3.1 原始负荷数据分析

选取中国某省市 2012 年 8 月份的电力负荷进行分析,图 2 显示了 8 月份每天 288 个点的负荷数据. 该市 8 月中的负荷数据主要分布在 1 200 ~ 2 400 MW 之间,每天均有两个波峰;为了解决原始数据(图 2 中左侧的尖峰)中的异常数据和噪声,实验选择二维小波阈值去噪方法<sup>[6]</sup>. 预处理后,选择 1 日至 28 日负荷进行训练,29 日至 31 日负荷用于测试.




图 2 某省市 8 月份日负荷曲线

Fig.2 Daily load curve from august in some city

3.2 气象数据分析

负荷样本数据选择的时间是 8 月份,此时,主要考虑气象因素中的温度、湿度、气压和风速对负荷的影响. 使用 MATLAB7 中的 corrcoef 命令,得出了该省市气象局各气象因子与负荷之间的关系,如图 3 所示. 由图 3 可以看出,负荷与温度正相关,与湿度负相关,与气压总体呈正相关,与风速总体呈负相关. 对气象因子进行量化时,因子呈正相关且相关系数越接近 1 量化值越大;越接近于 0 量化值越小;因子呈负相关,且相关系数越接近 -1 量化值越小,越接近于 0 量化值越大.

3.3 单一预测模型预测效果分析

采用 ARMA、SVM、PSO-SVM 和 BP 4 种单一模型对负荷进行预测,预测结果分别为  $f_1$ 、 $f_2$ 、 $f_3$  和  $f_4$ ,预测效果如表 1 所示. 由表 1 可以看出,BP 模型的预测效果最差,PSO-SVM 模型的预测效果最好<sup>[4]</sup>,故在组合预测模型时剔除 BP 模型.




图 3 某日负荷与气象因子之间的关系

Fig.3 The relationship between meteorological factors and load in some day

表 1 单一预测模型预测效果对比  
Tab.1 Effect contast among singe prediction model

单一预测模型	预测精度 $f/\%$	MSE
ARMA	98.18	3 601.4
BP	97.29	3 820.8
SVM	98.23	3 570.7
PSO-SVM	98.44	3 475.2

3.4 组合预测模型效果分析

根据公式(2)~(6)中的  $E$  求权值步骤可得出 3 种单一模型的  $h_i = \{0.918\ 0, 0.930\ 0, 0.950\ 0\}$ ,  $d_i = \{0.082\ 0, 0.070\ 0, 0.050\ 0\}$ ,  $w_{4i} = \{0.297\ 1, 0.326\ 6, 0.376\ 3\}$ . 同时,由公式(7)~(9)可分别求得 EW 法、SWA 法和 MSEC 法得到的权重值分别为  $w_{1i}$ 、 $w_{2i}$  和  $w_{3i}$ ,组合成权重矩阵  $W$  如式(11)所示.

$$W = \begin{bmatrix} w_{11} & w_{12} & w_{13} \\ w_{21} & w_{22} & w_{23} \\ w_{31} & w_{32} & w_{33} \\ w_{41} & w_{42} & w_{43} \end{bmatrix} = \begin{bmatrix} 1/3 & 1/3 & 1/3 \\ 0.011\ 8 & 0.497\ 1 & 0.491\ 1 \\ 6/12 & 2/12 & 4/12 \\ 0.297\ 1 & 0.326\ 6 & 0.376\ 3 \end{bmatrix} \quad (14)$$

将式(14)中对应各值分别代入式(1)、(10)和式(11),即可得出 12 组组合模型. 通过模型评价体系如公式(12)、(13),得出 12 组组合模型的 MAPE 和 MSE,如表 2 所示.

由表 2 可看出,组合模型 WHAC-E 模型的预测效果和预测精度是 12 组组合模型中最优的. 图 4 为 WHAC-E 组合模型的预测结果图.

表 2 组合模型预测效果分析  
Tab.2 Combination mode forecast effect analysis

预测模型	MAPE	MSE
LC-EW	0.012 2	3 153.6
LC-MSEC	0.013 4	3 442.2
LC-SWA	0.012 3	3 161.4
LC-E	0.011 7	3 110.8
WGMC-EW	0.012 1	3 146.3
WGMC-MSEC	0.013 4	3 442.7
WGMC-SWA	0.012 3	3 161.3
WGMC-E	0.012 4	3 167.5
WHAC-EW	0.011 9	3 119.3
WHAC-MSEC	0.021 0	3 629.5
WHAC-SWA	0.017 2	3 519.1
WHAC-E	0.011 5	3 102.9




图 4 WHAC-E 组合模型的预测结果  
Fig.4 Forecast effects of WHAC-E combination model

4 结束语

笔者将证券组合分析法思想应用在短期电力

负荷之中,通过寻找最优组合模型完成对短期电力负荷的预测,通过算例分析验证了 WHAC-E 模型在短期负荷预测中具有有效性和精确性,下一步的研究方向是:研究负荷与气象因素深层次的关系,获得更加严谨的气象量化值,从而获得更加科学原始输入矩阵;分析单一模型预测误差与组合模型权重之间的深层次关系.

参考文献:

[1] 牛东晓,魏亚楠. 基于 FHNN 相似日聚类自适应权重的短期电力负荷组合预测[J]. 电力系统自动化, 2013,37(3):54-57.

[2] 周德强,武本令. 灰色 BP 神经网络模型的优化及负荷预测[J]. 电力系统保护与控制,2011,39(21):65-68.

[3] 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):43-51.

[4] 陆宁. 基于群集智能与算法融合的电力负荷组合预测[M]. 武汉:华中科技大学,2010.

[5] 刘双,杨丽徙,王志刚,等. 基于 Matlab 神经网络工具箱的电力负荷组合预测模型[J]. 电力自动化设备,2003,23(3):53-61.

[6] 童述林,文福拴. 电力负荷数据预处理的二维小波阈值去噪方法[J]. 电力系统自动化,2012,36(2):101-104.

Short-term Load Forecasting Based on WHAC-E Combination Model

SU Shi-mei<sup>1</sup>, WANG Ming-xia<sup>1</sup>, YAO Meng<sup>2</sup>, ZHANG Jian-hua<sup>1</sup>

(1. Shool of Electrical Engineering, Zhengzhou Univesity, Zhengzhou 450001, China; 2. Xinxiang Power Supply Company, Xinxiang 450003, China)

**Abstract:** This paper proposes four single models, and they are regressive moving averag model, neural network model, support vector machine model and particle swarm optimization support vector machine model. We make use of the thought of non optimal combination forecast in operation research, linear combination, the weighted geometric means combination and the weighted harmonic average portfolio 3 combinations of models and other rights law, a simple weighted average method , the mean square error countdown France and entropy 4 combinations model weights solving methods are used; Supported by some power company original load log data and real-time meteorological data of some three day, numerical example analyse and verify that proposed combination forecasting model has validity and accuracy when it’s used short-term load and it provide a reference for the short-term load forecast.

**Key words:** load forecasting; sngle prediction model; entropy; wighted harmonic average; combination forecasting