

一种基于 HHT 的电力系统短期负荷预测模型

白玮莉, 刘志刚, 彭权威, 周翔

(四川省建筑设计院, 四川 成都 610017)

摘要: 提出了一种基于 HHT 的电力系统短期负荷预测模型。针对 EMD 分解电力负荷时存在模态混叠及对高频 IMF 预测不准确的问题, 采用一阶差分算法对 EMD 分解进行改进, 得到消除模态混叠后的一系列 IMF 分量及余项。通过对各分量的频谱计算和观察, 提取出低频分量, 并将其进行重构, 各分量选取合适模型进行预测。由于 IMF1 主要为负荷的随机分量, 对其考虑天气、节假日因素, 并采用粒子群算法对组合权值进行优化。仿真结果表明此种方法具有较高的预测精度。

关键词: HHT; 模态混叠; 差分算法; 频谱; 粒子群算法优化

A power system short-term load forecasting model based on HHT

BAI Wei-li, LIU Zhi-gang, PENG Quan-wei, ZHOU Xiang

(Sichuan Architectural Design Institute, Chengdu 610017, China)

Abstract: A short-term load forecasting model based on HHT is proposed. Due to the mode-mixing phenomenon when the power load data is decomposed by EMD and the problem of the IMF with high frequency is difficult to forecast, the first difference algorithm is used to improve EMD decomposing, then several IMFs and remainder without mode-mixing can be obtained. Through calculating and observing the spectrum of decomposed series, the low frequency IMFs are extracted and reconstructed, which can be forecasted with appropriate forecasting model. Since IMF1 is mainly as the random component of load, factors such as temperature and weekday are taken into consideration, and PSO is used to optimize the combination weights. Simulation results indicate that PSO has higher forecasting accuracy.

Key words: HHT; mode-mixing; difference algorithm; spectrum; PSO

中图分类号: TM715 文献标识码: A 文章编号: 1674-3415(2011)02-0055-06

0 引言

短期负荷预测经历了从时间序列法、回归分析法、指数平滑法等经典预测方法到灰色系统理论、人工神经网络、模糊逻辑、小波分析、混沌理论、支持向量机的现代预测方法。传统的预测方法比较成熟, 预测结果具有一定的参考价值, 但预测精度有待提高。现代预测方法相比来说有更高的预测精度, 围绕它进行的研究也越来越深入广泛。近几年出现了基于 EMD 的短期负荷预测, 文献[1-3]均采用 EMD 方法对负荷数据进行分解, 然后分别对各分量和余项采用同一种预测模型进行预测, 最后将这些预测分量加起来作为最终的预测结果, 它们利用 EMD 的优点成功地提高预测精度, 但没有考虑每个分量

的特点及预测方法的适应性, 具有一定的不合理性。文献[4]将 EMD 分解后的子序列重构成三个分量, 用三种不同的预测方法进行预测, 这与利用 EMD 分解提高预测精度的初衷自相矛盾。另外经本人进行大量的实际数据测试发现, 利用 EMD 进行预测的误差主要来源于高频分量, 减小预测误差关键在于提高对高频分量的预测精度。本文提出基于 HHT 的电力系统负荷预测模型, 该模型利用一阶差分算法消除 EMD 模态混叠, 通过对各分量的频谱计算和观察, 将低频分量进行重构, 选取合适模型对各个分量进行预测。由于 IMF1 主要为负荷的随机分量, 其波动性大, 本文提出对其利用组合预测模型, 并利用粒子群算法对组合权值进行优化, 仿真结果表明此种方法具有较高的预测精度。

1 HHT 算法简介

HHT^[5] (Hilbert-Huang Transform) 是全新的信号处理方法, 它由经验模态分解法 (Experience

基金项目: 教育部新世纪优秀人才支持项目 (NECT-08-0825); 教育部霍英东青年教师基金资助项目 (101060); 四川省杰出青年基金项目 (07JQ0075)

Mode Decompose, EMD)及Hilbert变换两部分组成。EMD是由N.E Huang提出的用于分解非线性、多分量信号的分解方法。通过EMD分解出来的各个分量,我们称之为固有模态分量(IMF),通过每个分量我们可以得到精确的瞬时频率和幅值(通过Hilbert变换得到)表达式,瞬时频率与幅值可看作作为一种能量谱,显示组成信号的频率成分,这样为信号时频分析带来极大便利。此算法的目的是把复杂信号分解为简单的单分量信号的组合,即将性能不好的信号分解为一组性能较好的具有瞬时频率的固有模态函数(IMF)和具有单调性或一个极值点的余项 R_n 。该方法分解过程基于数据信号局部特征,不需要预先设定参数,是自适应的。分解得到的IMF分量都是平稳的,包含原始信号的局部特征信息,尤其适用于非线性和非平稳性数据。近几年该法已经被应用于地球物理学、生物医学、工学等领域的研究,并取得了较好的效果。

2 EMD 模态混叠解决方法

电力负荷可表示为周期分量、随机变化量与趋势分量之和。将EMD应用在电力负荷数据的分解中时,如果能实现将各个模态很好的分离,得到的每个IMF分量之间不存在模态混叠,那么基于此,对于各个IMF分量选择不同预测模型,就能达到更高的预测精度。

现阶段消除模态混叠主要有如下方法:(1)基于Fourier谱的滤波法:Yang等人^[6-7]将Fourier变换引入EMD筛分过程,实践证明这一方法非常适于强迫振动动力响应的模态分解。但对于电力负荷数据由于本身数据不存在特定的稳定的频率成分,每个模态只是近似为频率或幅值调制的正余弦函数,所以当用此种方法存在无法有效区分各频带成分,设置滤波器参数的问题。(2)采用间歇检测准则法。但该方法存在在间断频率的选择上主要是靠经验来进行确定,有很大的主观性,对IMF中点间数据大于 N 的两极值点进行忽略的做法极易破坏原信号的完整性和连续性的缺点,所以应用不多。(3)Ryan Deering等人^[8]提出了在EMD过程中加入伪信号的解决方法,该方法的本质是使加入的伪信号在EMD过程中与复合信号中所包含的高频信号相混淆,从而达到把高频信号从低频信号中提取出来的目的,但是由于复合信号所包含的信号的频率本身也非常接近,所以伪信号在与高频信号产生混淆的同时也可能会与低频信号产生混淆,从而影响分解的效果。(4)差分方法^[9]。此种方法通常应用在低频强信号混有高频弱噪声的情形,假设混叠模态信号 $x(t)$ 中含有2种模态,既 $x(t) = a_1 \sin(\omega_1 t) +$

$a_2 \sin(\omega_2 t)$,而由EMD的二进滤波特性,这里不妨假设 $\omega_1 \geq 2\omega_2$, $a_1 < a_2$ 。由EMD能正确分解多频信号的充分条件,即 $A_1\omega_1 > A_2\omega_2$ (A_1, A_2 表示2种模态的幅度),此时成功分离两模态必须满足 $a_1 > a_2 / 2$,当低频强信号混有高频弱噪声时,此种条件一般达不到,而对其进行差分运算后,将得到 $x'(t) = a_1\omega_1 \cos(\omega_1 t) + a_2\omega_2 \cos(\omega_2 t)$,此时成功分离的条件将为 $a_1 > a_2 / 4$,实现模态分离将更容易实现。

3 本文提出的模型原理和方法

针对EMD模态混叠及IMF1高频随机成分难以预测的问题,本文提出的预测方法如下。

(1)利用小波^[10]及莱特准则(在测量数据为正态分布、且测量次数足够多时,如果某个测量数据的剩余误差的绝对值大于3倍标准差,可以认为该测量值为异常数据,修改方法:使其值的剩余误差等于3倍标准差)对预测原始数据进行去噪及去除异常值;

(2)采用一阶差分方法对EMD进行改进,消除模态混叠;

(3)通过频谱分析提取出低频分量,由于其频率低,波动小,显示负荷中的长期变化趋势,将低频信息进行重构,这样可减少预测步骤及复杂性,同时不失准确度;

(4)根据各分量具有不同频率特性,分别选取合适的模型对其进行预测;

(5)将各个IMF预测值相加得到最终的预测结果。

4 负荷序列EMD分解

电力负荷存在峰荷、腰荷与基荷,其模态混叠的原因主要是由于其能量差异过大,峰荷数据淹没在腰荷与基荷中,腰荷又隐藏在基荷中,这种数据特征正好与低频信号混有高频弱噪声相类似。

如图1为重庆电网2006年7月1日~8月25号电网负荷数据,图2为采用标准EMD方法对负荷数据进行分解的结果,图3为各个IMF分量的频谱图,从图2可以看出分解结果从IMF2开始存在模态混叠现象,同时从图3可观察到各IMF分量的瞬时频率波动大。对此我们运用差分方法对其进行实验仿真,如图4为运用差分方法得到的EMD分解结果,图5为用此种方法分解的各IMF分量频谱,对比图2与图4,图3与图5我们可以清楚地看出差分方法可进行有效

的模式分离, 各IMF分量更趋近于窄带平稳信号。

定义EMD分解误差为:

$$Error = s(t) - \sum_{i=1}^l c_i(t) \quad (1)$$

式中: $s(t)$ 为原始负荷数据, MW; $c_i(t)$ 为第*i*个IMF分量, MW。

分解误差如图6所示,可看出算法造成的分解误差可忽略不计,能够保证信号的完备性。

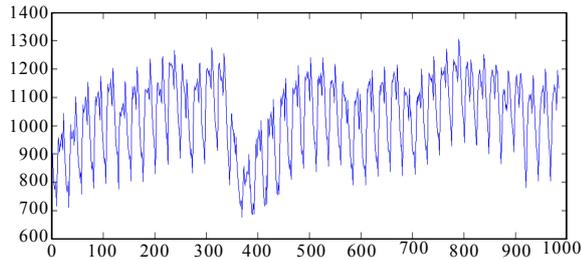


图1 原始负荷数据

Fig.1 Original load data

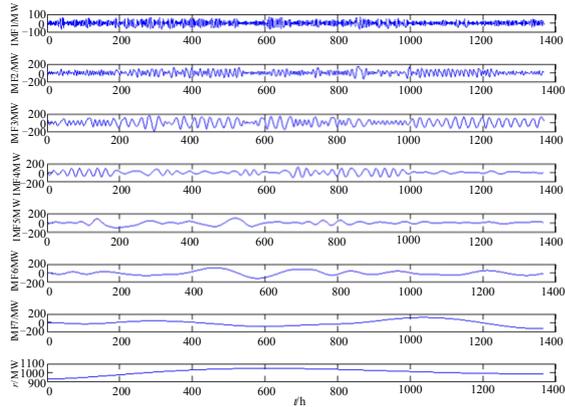


图2 标准EMD分解结果

Fig.2 Decomposed components of standard EMD

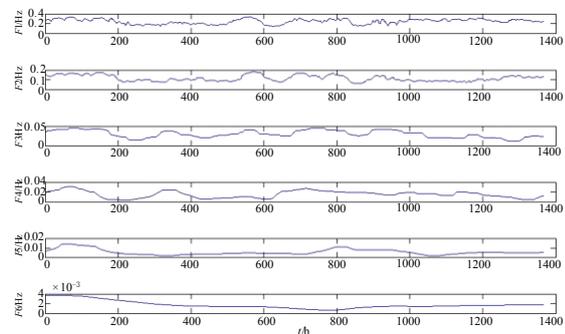


图3 标准EMD瞬时频谱

Fig.3 Instantaneous spectrum of components decomposed by standard EMD

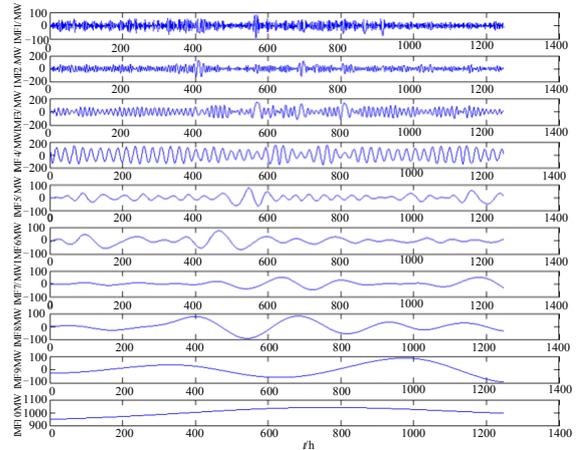


图4 运用差分方法EMD分解

Fig.4 Decomposed by difference algorithm EMD

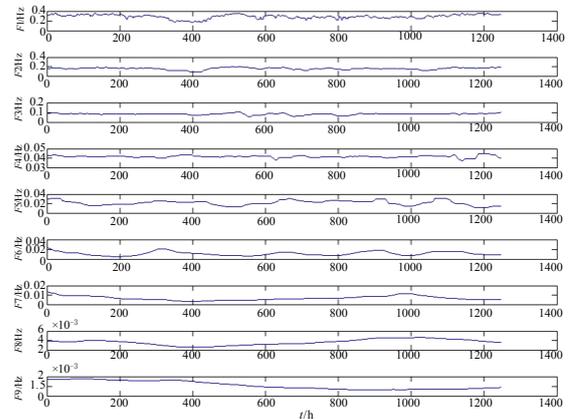


图5 差分EMD瞬时频谱

Fig.5 Instantaneous spectrum of components decomposed by difference algorithm EMD

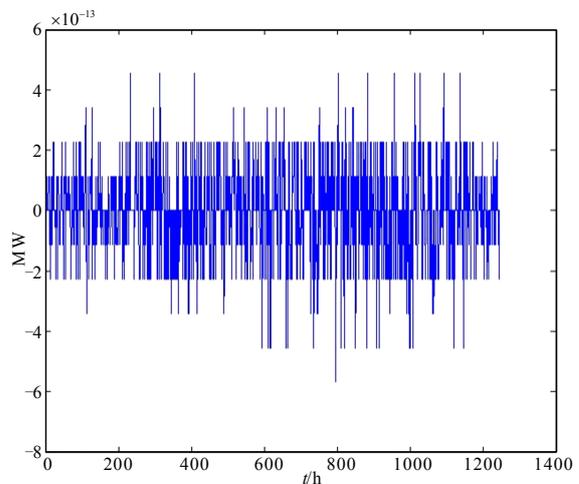


图6 误差

Fig.6 Errors

5 预测模型

本文针对各IMF分量在频域及时域上的不同特点,分别采取不同预测模型。如图4、5所示,由于EMD分解余项存在明显的线性特征,采用线性神经网络对其预测; IMF2~8其周期性明显,频率较为稳定,本文采用SVM对其进行预测;对于IMF1其主要为电力负荷的随机成分,频率不稳定,波动性明显,受外界温度、节假日等因素影响较大,对它的预测单一采用一种方法不能达到较好的效果,本文提出利用粒子群优化算法对线性组合模型的参数进行优化,并与传统线性组合模型及神经网络组合模型进行比较。

5.1 支持向量机SVM

支持向量机SVM的机器学习算法,实现了结构风险最小化原理(SRM),找到经验风险最小和推广能力最大的平衡点,对未来样本有较好的泛化性能^[11]。SVM算法的计算结果稳定,不像一般算法具有一定的随机性,而且SVM算法不会陷入局部最优值,用于负荷预测具有一定的优势。

5.2 组合模型

传统线性组合预测模型求权重系数的方法往往比较简单。粒子群是一种基于迭代的优化工具,在算法实现过程中没有交叉变异操作,而是以粒子对解空间中最优粒子的追随进行解空间的搜索,优点在于流程简单易实现,算法参数简洁,无需复杂调整^[12],因此为取得更好的参数优化结果,本文提出采用粒子群算法对权重系数进行优化,并采用基于神经网络的组合预测模型与其进行效果对比。预测结果表明,PSO优化线性模型与神经组合模型都具有较好的预测效果,预测精度高于传统线性组合模型及单一模型。

5.2.1 基于粒子群算法(PSO)的线性组合模型

线性组合模型的具体表达式如下:

$$\begin{cases} y_t = k_1 y_{1t} + k_2 y_{2t} + k_3 y_{3t} \\ k_1 + k_2 + k_3 = 1, \quad k_i \geq 0 \quad (i=1,2,3) \end{cases} \quad (2)$$

式中: y_{1t} , y_{2t} 和 y_{3t} 分别为三种模型的预测值; k_1 , k_2 和 k_3 为权重系数; y_t 为组合预测值。

在粒子群算法中,假设由 N 个粒子搜索 Q 维空间,每个粒子的位置可表示为 $x_i = (x_{i1}, x_{i2}, \dots, x_{iQ})$, 其速度可表示为 $v_i = (v_{i1}, v_{i2}, \dots, v_{iQ})$ 。粒子需要跟踪的两个极值是单个粒子的历史最优位置 P_i 和所有粒子的全局最优位置 P_g , 找到这两个位置后,粒子更新自己的位置,其更新公式为

$$v_i^{k+1} = wv_i^k + c_1 u(P_i^k - x_i^k) + c_2 \eta(P_g^k - x_i^k) \quad (3)$$

$$\begin{aligned} v_i^{k+1} &= v_{\max} & v_i^{k+1} > v_{\max} \\ v_i^{k+1} &= v_{\min} & v_i^{k+1} < v_{\min} \\ x_i^{k+1} &= x_i^k + \beta v_i^k \end{aligned} \quad (4)$$

式中: w 是保持原来速度的系数,称为惯性权重; c_1 是粒子跟踪自己历史最优值的权重系数,它体现了粒子对自身的认知能力; c_2 是粒子跟踪群体最优值的权重系数,它体现了粒子对整个群体知识的认知能力; u , η 是 $[0, 1]$ 区间内均匀分布的随机数; β 是对位置更新时,与速度有关的一个系数,称为约束因子。 v_{\max} 、 v_{\min} 分别为速度最大、最小值。

本文采取 30 个粒子搜索 3 维空间,优化目标函数为:

$$f = \text{mean}(y_t - (k_1 y_{1t} + k_2 y_{2t} + k_3 y_{3t})) + 50(1 - (k_1 + k_2 + k_3)) \quad (5)$$

$\text{mean}(y_t - (k_1 y_{1t} + k_2 y_{2t} + k_3 y_{3t}))$ 代表真实值与组合预测值各点相差的平均值, $50(1 - (k_1 + k_2 + k_3))$ 为约束函数,使得 $k_1 + k_2 + k_3$ 接近 1, 迭代条件为 $f > 8$, 即在迭代过程中粒子跟踪 f 的值,最终求出 k_1 , k_2 和 k_3 的最优解,完成对 k_1 , k_2 和 k_3 的参数优化。

5.2.2 神经网络的组合预测模型

设 f_{1i} , f_{2i} , f_{3i} 分别是三种预测模型的第 i 次预测结果,而 f_i 是第 i 次的实际负荷值,如果认为它们之间是较复杂的非线性关系,则有:

$$\sum_{i=1}^m [f_i - g(f_{1i}, f_{2i}, f_{3i})]^2 \quad (6)$$

其中: m 为样本个数,为了使得式(6)取得最小值,就是要求出非线性函数 $g(\bullet)$ ^[13]。本文采用的是BP神经网络,将各种神经网络的预测值作为BP的输入,实际值作为输出对网络进行训练。

6 数据仿真

如图4所示,利用差分EMD方法原始负荷数据被分解为10个IMF分量。如果对于每个IMF分量单独采用预测模型对其进行预测,工作量大而繁琐。通过Hilbert变换,各IMF分量的平均瞬时频率如表1,单位Hz。

从表1可看出IMF分量频率依次从高到低,基本上存在2倍的关系。IMF7~9的瞬时频率较低,可

以认为它们为负荷的长期波动成分, 将它们进行重构并定义为 IMF7, 另外加上余项, 这样分量总数降为 8 个, 从而减少预测分量的数量。对于 8 个新分量, IMF2~7 采用 SVM 方法, 余项采用线性神经网络进行预测。它们模型均采用前 20 点负荷值来预测当前点负荷值。经过实际数据测试证明能达到较好的预测效果。IMF2~7 及余项的预测效果如图 7 所示。

表 1 IMF 分量平均瞬时频率

Tab.1 The average instantaneous frequency of each IMF

IMF1	IMF2	IMF3	IMF4	IMF5	IMF6	IMF7	IMF8	IMF9
0.29	0.16	0.08	0.04	0.02	0.01	0.007	0.004	0.002

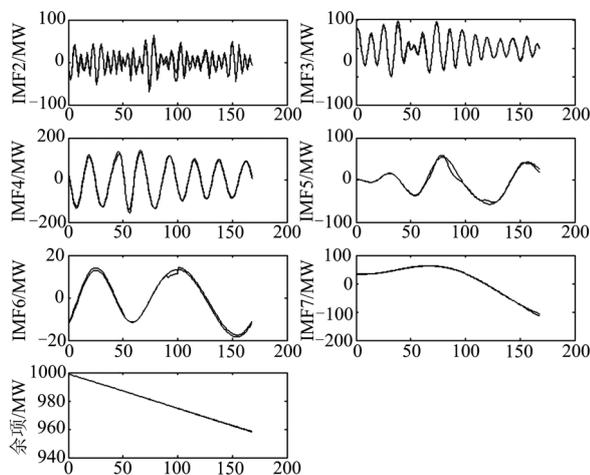


图 7 IMF2~7 预测效果

Fig.7 Forecasting results of IMF2~7

对于 IMF1 本文利用 SVM、BP、RBF 分别对其预测, 并考虑温度与节假日。对每个小时建立预测模型, 24 次重复建模, 输入层神经元的选择依次为预测日前 2 天同一时刻及前两时刻的负荷值、最低、最高温度、节假日类型 (节假日取值为 1, 工作日取值为 0)、预测日前 1 天同一时刻、前两时刻的负荷值、最低、最高温度、节假日类型、预测日当天的前 2 个时刻的负荷值、最低、最高温度、节假日类型, 共 17 个神经元, 输出层为负荷的实际值。然后基于 SVM、BP、RBF 三种预测结果分别进行传统线性组合、PSO 优化组合和神经网络组合预测。为了验证方法的实用性和准确性, 将 7 月 1~8 月 15 号负荷数据作为训练样本, 对 8 月 16 日~8 月 22 日一周负荷数据进行预测。

设负荷实际值为 $R(i)$, 预测值为 $Y(i)$ 则每点相差值为:

$$d_i = |R(i) - Y(i)| \quad (7)$$

相对预测误差:

$$e_i = |[R(i) - Y(i)] / R(i)| \times 100\% \quad (8)$$

$$\text{平均误差: } ee = \frac{1}{24} \sum_{i=1}^{24} e_i \quad (9)$$

图 8 中五副图分别为 RBF、BP、SVM、传统线性组合、PSO 优化线性组合模型、神经网络组合模型对 IMF1 预测的结果与 IMF1 真实值的比较。用 C1 代表传统线性组合模型、C2 代表 PSO 优化线性组合模型、C3 代表神经网络组合模型, 表 2 列出了各模型预测的相差值, 从中可看出, 组合模型的预测精度比单一的预测模型高。表 3 列出了对 IMF1 采取不同预测模型情况下总预测结果的误差, 可看出 PSO 优化线性组合模型与神经网络组合模型预测精度较高。

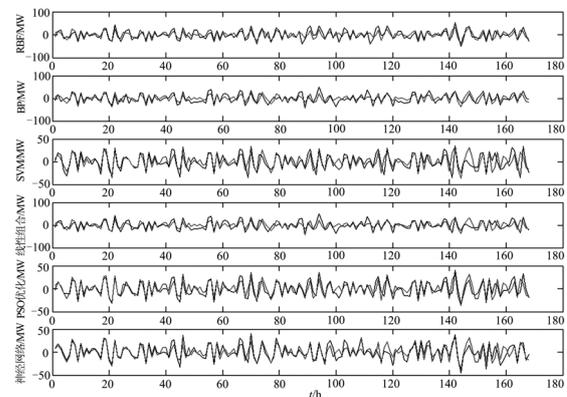


图 8 IMF1 各模型预测比较

Fig.8 Comparison of each model forecasting for IMF1

表 2 IMF1 各种模型相差值比较

Tab.2 Errors of each model forecasting for IMF1

相差/MW	RBF	BP	SVM	C1	C2	C3
最大相差	48.52	32.11	45.58	30.14	28.83	25.79
平均相差	11.52	11.84	9.37	8.18	7.61	6.48

7 结论

本文提出基于 HHT 的电力系统短期负荷预测模型, 针对负荷噪声、异常值、EMD 模态混叠、高频 IMF1 分量受外界因素影响, 随机波动性大等问题, 该模型考虑外部天气及节假日影响因素, 对一周负荷进行预测, 考虑分析全面。提出负荷数据经小波和莱准则进行降噪及去除异常值, 然后对负荷数据利用改进后的 EMD 进行分解, 在一定程度上消除了模态混叠, 使 IMF 各个分量频带更为集中, 从而降低预测复杂度, 通过对各分量频谱的观察, 提取出低频分量进行重构, 在不影响预测精度的基础上减少预测步骤。对于 IMF1 高频分量本文

采用多种方法进行对比, 结果证明 PSO 优化组合模型与神经网络组合模型均具有较高的预测精度, 实现了整体负荷预测精度的提高。

表 3 各模型预测结果误差

Tab.3 Forecasting errors of each mode

日期	最大误差/%						平均误差/%					
	RBF	BP	SVM	C1	C2	C3	RBF	BP	SVM	C1	C2	C3
16	3.9	3.85	3.47	3.35	3.05	2.41	1.5	1.52	1.26	1.30	1.01	0.87
17	4.6	4.81	5.06	4.78	4.64	4.85	1.3	1.34	1.20	1.22	1.10	0.98
18	6.05	6.09	5.48	5.87	5.74	5.52	2.25	1.77	1.85	1.93	1.87	1.78
19	5.47	4.64	4.50	4.51	4.39	5.0	1.77	1.90	1.52	1.54	1.48	1.53
20	4.24	4.77	3.33	3.44	3.21	3.18	1.90	1.51	1.26	1.37	1.26	1.29
21	3.41	3.51	4.80	3.59	2.77	3.25	1.60	1.45	1.45	1.30	1.27	1.13
22	4.26	4.43	6.22	4.58	4.43	4.30	1.64	1.42	1.89	1.55	1.35	1.55

参考文献

[1] ZHU Zhi-hui, SUN Yun-lian, LI Huang-qiang. Hybrid of EMD and SVMs for short-term load forecasting[C]// IEEE International Conference on Control and Automation. 2007: 1044-1047.

[2] 王洪波, 朱启兵. 基于 EMD 和 LS-SVM 的非平稳振动信号趋势预测[J]. 计算机工程与应用, 2008, 44 (16): 157-159.

WANG Hong-bo, ZHU Qi-bing. Trend prediction of nonstationary vibration signals based on empirical mode decomposition and least square support vector machine[J]. Computer Engineering and Applications, 2008, 44 (16): 157-159.

[3] 谢景新, 程春田, 周桂红, 等. 基于经验模式分解与混沌分析的直接多步预测模型[J]. 自动化学报, 2008, 34 (6): 684-689.

XIE Jing-xin, CHENG Chun-tian, ZHOU Gui-hong, et al. A new direct multi-step ahead prediction model based on EMD and chaos analysis[J]. Journal of Automation, 2008, 34 (6): 684-689

[4] 李媛媛, 牛东晓, 乞建勋, 等. 基于分散经验模式分解的电力负荷混合预测方法[J]. 电网技术, 2008, 32 (8): 58-62.

LI Yuan-yuan, NIU Dong-xiao, QI Jian-xun, et al. A novel hybrid power load forecasting method based on ensemble empirical mode decomposition[J]. Power System Technology, 2008, 32 (8): 58-62.

[5] LOH C H, WU T C, HUANG N E, et al. Application of emd+hht method to identify near-fault ground motion characteristics and structural responses[J]. BSSA, Special, Issue of Chi-Chi Earthquake, 2001, 91 (5): 1339-1357.

[6] Yang J N, Lei Y, Pan S W, et al. System identification of linear structures based on hilbert-huang spectral analysis, part 1: normal modes[J]. Earthquake Engineering and Structural Dynamics, 2003, 32: 1443-1467.

[7] Yang J N, Lei Y, Pan S W, et al. System identification of linear structures based on hilbert-huang spectral analysis, part 2: complex modes[J]. Earthquake Engineering and Structural Dynamics, 2003, 32: 1533-1554.

[8] Ryan Deering, James F Kaiser. The use of a masking signal to improve empirical mode decomposition[C]. //Acoustics, Speech and Signal Processing, 2005, Proceedings, ICASSP'05, IEEE International Conference. 2005, 4: 485-488.

[9] 高云超, 桑恩方, 许继友. 分离 EMD 中混叠模态的新方法[J]. 哈尔滨工程大学学报, 2008, 29 (9): 963-967.

GAO Yun-chao, SANG En-fang, XU Ji-you. A new method for separating mixed modes in empirical mode decomposition[J]. Journal of Harbin University of Engineering, 2008, 29 (9): 963-967.

[10] 徐仁林, 安伟. 小波降噪在信号基于 EMD 的 Hilbert 变换中的应用[J]. 噪声与振动控制, 2008, 6(3): 74-77.

XU Ren-lin, AN Wei. Wavelet denoise application in the signal hilbert transform based on EMD[J]. Control of Noise and Vibration, 2008, 6 (3): 74-77.

[11] 田有文, 唐晓明. 基于支持向量机的微机保护装置状态评估的研究 [J]. 电力系统保护与控制, 2009, 37(17): 66-69.

TIAN You-wen, TANG Xiao-ming. Study on state evaluation for microprocessor protective device based on SVM[J]. Power System Protection and Control, 2009, 37 (17): 66-69.

[12] 常文平, 于海. 基于自适应粒子群优化算法的机组组合[J]. 电力系统保护与控制, 2009, 37(9): 15-18.

CHANG Wen-ping, YU Hai. A solution to particle swarm optimization algorithm with adaptive inertia weight for unit commitment[J]. Power System Protection and Control, 2009, 37(9): 15-18.

[13] 郑连清, 郑艳秋. 基于经验模式分解与人工神经网络的短期电力负荷预测[J]. 电力系统保护与控制, 2009, 37(17): 15-18.

ZHANG Lian-qing, ZHENG Yan-qiu. Short-term power load forecasting based on empirical mode decomposition and ANN[J]. Power System Protection and Control, 2009, 37(17): 15-18.

(下转第 64 页 continued on page 64)

表 2 仿真结果电流对比表

Tab.2 Comparison of current simulation results

电容器布置	I_1	I_3	I_5	I_7	I_9	I_{11}	I_{13}	I_{15}	$THD_i/\%$
优化前	834.37	5.43	180.98	112.35	4.22	75.52	55.23	22.85	27.90
优化后	894.22	6.56	95.13	56.36	7.23	58.45	26.32	12.88	14.41

注: $THD_i = \sqrt{\sum_{h=2}^{15} (\frac{I_h}{I_1})^2} \times 100\%$, 为谐波总畸变率

不进行电容器布置优化时,从图 5 (a) 可以看出,在非线性负载以及母线畸变电压的作用下,通过电力电容器的电流所含谐波比较多,谐波电流畸变严重。由表 2 可知,此时,电流总谐波畸变率为 27.90%,超过对电流谐波总畸变率的要求。进行电容器布置优化后,从图 5 (b) 可以看出,电容器电流中谐波相对较少,电流总谐波畸变率为 14.41%,由表 3 可知谐波电压也有很好的改善,谐波抑制效果比较理想。

表 3 仿真结果电压对比表

Tab.3 Comparison of voltage simulation results

电容器布置	U_1	U_3	U_5	U_7	U_9	U_{11}	U_{13}	U_{15}	$THD_u/\%$
优化前	226.89	0.23	7.49	6.58	0.23	1.36	0.45	0.16	4.44
优化后	233.77	0.45	3.97	3.97	0.24	4.44	1.17	0.17	3.11

4 结论

工业配电系统中,对通过电力电容的谐波电流分析时,可以将谐波源可分为两类,一是母线电压畸变引起的谐波电压源,另一个是相邻非线性设备运行所产生的谐波电流源。如果在谐波源作用下,系统阻抗与电容器发生谐振,将大大增加通过电容器的谐波电流,从而损害电容器。以基于 ANN 测量分析法得到的谐波电流畸变率 THD 为目标函数,找到电容器组的最优布置,可以有效地减弱或避免谐振的影响,通过仿真验证了该方法的有效性。ANN 算法由于其精确性高,计算量小,易于在 DSP 上实现的优点,使本文推荐的方法在工程上有很好的应用价值。

参考文献

[1] 王葵,李建超,蒋丽,等. 谐波电流对低压配电网的影

响分析[J]. 继电器, 2008, 36 (7): 31-35.

WANG Kui, LI Jian-chao, JIANG Li, et al. Influence analysis of harmonic current on low-voltage distribution power system[J]. Relay, 2008, 36 (7): 31-35.

[2] 周勇,赵慧光,王文峰. 无功补偿电容器谐波过载分析[J]. 继电器, 2005, 33 (16): 93-95.

ZHOU Yong, ZHAO Hui-guang, WANG Wen-feng. Harmonic overloading analysis of reactive compensation capacitor[J]. Relay, 2005, 33 (16): 93-95.

[3] Wakileh G J. 电力系统谐波-基本原理、分析方法和滤波器设计[M]. 徐政,译. 北京:机械工业出版社,2003. Wakileh G J. Power system: harmonics fundamentals, analysis and filter design[M]. XU Zheng, trans. Beijing: China Machine Press, 2003.

[4] Valluvan K R, Kandasamy A S, Natarajan A M. A survey of voltage and current harmonics in various industries connected to a state electrical grid[J]. International Journal of Applied Engineering Research, 2008, 6(3): 801-816.

[5] 王兆安,杨君,刘进军. 谐波抑制和无功功率补偿[M]. 北京:机械工业出版社,2002.

WANG Zhao-an, YANG Jun, LIU Jin-jun. Harmonics suppressing and reactive power compensation[M]. Beijing: China Machine Press, 2002.

[6] 金明,刘远龙. 用于电力系统谐波分析的 ANN 算法[J]. 电网技术, 1997, 17 (5): 52-54.

JIN Ming, LIU Yuan-long. A new ANN harmonic analysis algorithm for power system[J]. Power System Technology, 1997, 17(5): 52-54.

[7] 王竟昌. 供电系统谐波[M]. 北京:中国电力出版社, 1998.

WANG Jing-chang. Power system harmonics[M]. Beijing: China Electric Power Press, 1998.

[8] 金雄飞,乐秀璠. 电网谐波测量方法评述[J]. 继电器, 2003, 31 (8): 11-14.

JIN Xiong-fei, LE Xiu-fan. A survey on measuring method for harmonic of network[J]. Relay, 2003, 31 (8): 11-14.

收稿日期: 2010-01-25

作者简介:

王铁松(1965-),男,高工,主要从事机电设计研究与电气安全评价工作。E-mail: tiesong85374689@sina.com

(上接第 60 页 continued from page 60)

收稿日期: 2010-01-19; 修回日期: 2010-03-13

作者简介:

白玮莉(1986-),女,硕士研究生,主要从事于电气设计

工作; E-mail: bwl1986@163.com

刘志刚(1975-),男,博士、教授、博士生导师,主要研究方向为现代信号处理及其在电力系统中的应用;

彭权威(1982-),男,硕士研究生,主要从事于电力系统调度自动化工作。