

# 基于小波变换和遗传算法优化神经网络负荷预测

刘 绚, 刘天琪

(四川大学电气信息学院, 四川 成都 610065)

**摘 要:**提出了采用小波变换和遗传算法优化神经网络的混合模型对电力负荷进行短期预测。首先通过小波变换,将原始负荷序列分解到不同的尺度上,然后根据不同的子负荷序列的特性分别建立相匹配的神经网络模型,采用遗传算法优化各神经网络模型的初始权值,最后对各分量预测结果进行重构得到最终预测值。采用成都某地区 2009 年的实际负荷对所提方法进行验证,实验结果表明基于该方法的负荷预测系统具有较高的预测精度。

**关键词:**负荷预测;神经网络;小波变换;遗传算法

**Abstract:** A novel short-term load forecasting method using wavelet transform and neural network optimized by genetic algorithm is proposed. Firstly, by the wavelet transform, the load series is decomposed into the subseries with different frequency characteristics, then according to the features of the decomposed components, the corresponding neural network models are constructed to forecast the components, finally the forecasting result is obtained by the reconstruction of the forecasting result of components. The genetic algorithm optimization is used to optimize the initial weights of neural network model of each decomposed subsequence. Experimental results show that the proposed forecasting method has a satisfactory accuracy.

**Key words:** load forecasting; ANN; wavelet transform; genetic algorithm

**中图分类号:** TM711 **文献标志码:** A **文章编号:** 1003-6954(2010)03-0015-04

负荷预测是电力系统管理现代化的重要内容之一,对电力系统的安全、经济、可靠运行具有重要作用。传统的负荷预测方法有时间序列法、回归分析法、灰色模型法<sup>[1]</sup>、支持向量机<sup>[2]</sup>等。这些方法模型简单便于使用,但预测精度低,难以满足负荷预测的要求。随着人工智能技术的发展,人工神经网络被广泛应用于负荷预测<sup>[3-6]</sup>,并成为其主要方法之一。径向基函数(RBF)神经网络<sup>[4]</sup>作为前向神经网络的一种主要形式,具有结构简单、学习快速的特点,但是从本质上讲,RBF神经网络算法属于梯度下降算法,初始连接权随机选取,一旦取值不当,就会引起网络的振荡、不收敛或训练时间过长,再加之实际问题往往是极其复杂的多维曲面,存在多个局部极值点,使得BP算法极易陷入局部极值点,泛化能力比较低。

遗传算法<sup>[7]</sup>是从自然进化的思想和理论发展而来的一种高效的并行全局搜索算法,该算法具有很好的鲁棒性,在解决全局优化问题方面取得了成功。用遗传算法优化设计神经网络,不仅容易获得全局最优解,还可以提高神经网络的泛化性能。

电力系统负荷序列明显地展现出以天和周为单位进行变化的周期性。因此负荷序列可以看作是多

个具有不同频率分量的叠加,所以可以通过对负荷序列进行频域分析将这些频率分量分离出来,对每个分量单独进行分析并根据其特性建模并预测。负荷中某些分量在时域上的表现是瞬时的、随机的,为了能捕获这一类分量的频率规律,用传统的时频分析方法就显得力不从心。

这里采用小波变换的方法,对负荷序列进行小波变换,将负荷序列分别投影到不同的尺度上,而各尺度可近似地看作各个不同的“频带”,这样各个尺度上的子序列分别代表了原序列中不同频域的分量,它们更加清楚地表现了负荷序列的周期性。根据小波分解后不同尺度上的负荷序列的不同特性建立相应的神经网络模型,利用遗传算法优化选取神经网络初始权重,最后将各负荷分量的预测结果叠加,得到预测结果。

## 1 小波分析基本原理

小波分析<sup>[8-11]</sup>是近年发展起来的一种用于信号分析的数学方法。它的主要思想是选择合适的小波基函数,然后对小波基函数通过如下方式生成函数族。

**基金项目:**国家科技支撑计划项目(批准号:2008BAA13B01)

$$\psi_{a,b}(t) = |a|^{-\frac{1}{2}} \psi\left(\frac{t-b}{a}\right) \quad (1)$$

再通过函数族  $\{\psi_{a,b}\}$  对信号进行分析。对于一个能量有限函数  $f(t)$ , 其连续小波变换定义为

$$W_f(a,b) = |a|^{-\frac{1}{2}} \int_{\mathbb{R}} f(t) \overline{\psi\left(\frac{t-b}{a}\right)} dt \quad (2)$$

相应的连续小波变换的逆变换方程为

$$f(t) = \frac{1}{C_\psi} \iint_{\mathbb{R}^2} W_f(a,b) \psi_{a,b}(t) \frac{da db}{a} \quad (3)$$

其中  $C_\psi$  满足下式

$$\iint_{\mathbb{R}^2} W_f(a,b) \overline{W_f(a,b)} \frac{da db}{a} = C_\psi \langle f, h \rangle \quad (4)$$

其中  $b$  代表时间上的位移, 而  $a$  则代表时间尺度,  $W_f(a,b)$  是指原信号  $f(t)$  在时间  $b$  处所包含的尺度为  $a$  的小波函数分量, 表示了信号  $f(t)$  小波函数  $\psi\left(\frac{t-b}{a}\right)$  相关联的程度。

1987 年, Mallat 根据多分辨率分析理解, 提出了小波分解与重构的快速算法, 称为马拉 (Mallat) 算法<sup>[8]</sup>, 即金字塔算法。该算法的计算程序如下。

小波分解就是由高分辨率的离散近似  $a_k^{j-1}$  不断分解为低分辨率的离散近似  $a_k^j$  和离散细节 (小波数)  $d_k^j$  的过程。

$$a_n^j = \sum_{k=-\infty}^{+\infty} \overline{h(2n-k)} a_k^{j-1} \quad (5)$$

$$d_n^j = \sum_{k=-\infty}^{+\infty} \overline{g(2n-k)} a_k^{j-1} \quad (6)$$

小波重构过程是小波分解过程的逆过程, 是由低分辨率的逼近系数  $a_k^j$  和小波系数  $d_k^j$  恢复出高分辨率逼近系数  $a_k^{j-1}$  的过程。

$$a_n^{j-1} = \sum_{k=-\infty}^{+\infty} h(n-2k) a_k^j + \sum_{k=-\infty}^{+\infty} g(n-2k) d_k^j \quad (7)$$

其中  $a_k^j$  和  $d_k^j$  为相应的小波分解系数,  $h_j$  和  $g_j$  为离散滤波器。

## 2 径向基函数神经网络

径向基函数 (RBF) 神经网络作为前向神经网络的一种主要形式, 具有结构简单、学习快速的特点, 而且已经从理论上证明, 只要给定足够多的网络隐层节点, RBF 神经网络可以以任意精度逼近任何单值连续函数。RBF 神经网络由输入层、隐层、输出层组成, 其中隐含层的作用是完成对输入量的非线性变换, 选取高斯基函数作为隐含层的激活函数, 网络的

在输出则由隐含层输出线性组合得到。

$$f(x) = \sum_{i=1}^m \omega_i \exp\left(-\frac{\|x - c_i\|^2}{2\sigma_i^2}\right) \quad (8)$$

式中,  $x$  为输入样本;  $c_i$  为第  $i$  个隐层节点的高斯核函数的中心值;  $\delta_i$  是第  $i$  个隐层节点的变量, 称标准化常数或基宽度;  $m$  为网络隐层节点的个数;  $\omega_i$  是第  $i$  个隐层节点到输出节点的权值。

对于隐含层单元中心矢量, 采用正交最小二乘法进行选取。对隐含层与输出层之间的连接权值应用递推最小二乘法进行学习训练, 其学习训练的目标是使总误差达到最小, 即

$$m \ln J = -\frac{1}{2} \sum_{i=1}^N \sum_{j=1}^L \epsilon_{ij}^2 = -\frac{1}{2} \sum_{i=1}^N \sum_{j=1}^L (y_{ij} - y_{0ij})^2 \quad (9)$$

其中,  $y_{ij}$  为当输入样本为  $x_i$  时, 输出层第  $i$  个单元的期望输出;  $\epsilon_{ij}$  为其拟合误差。

## 3 遗传算法的优化 RBF 神经网络初始权重

从本质上讲, RBF 算法属于梯度下降算法, 其学习结果对初始权向量异常敏感, 神经网络训练具有很大的盲目性, 初始连接权随机选取, 一旦取值不当, 就会引起网络的振荡、不收敛或训练时间过长, 再加之实际问题往往是极其复杂的多维曲面, 存在多个局部极值点, 有可能在网络权值参数优化时陷入局部极小, 使得网络的泛化能力及适应能力较差, 甚至带来死机和无法满足精度要求的情况。

遗传算法是基于自然选择和自然基因的搜索算法, 通常由三个基本操作组成: 选择、交叉和变异。GA 通常应用于神经网络权值训练, 网络结构的设计以及寻找最优学习规则<sup>[12-14]</sup>。由于通过实验已经确定了网络的结构, 所以, 此处只用遗传算法进行神经网络权值修正。具体实现如下。

### (1) Gray 编码

传统的二进制编码可能具有较大的 Hamming 距离, 这种缺陷将降低遗传算子的搜索效率。二进制编码的这一缺点有时被称为 Hamming 悬崖。而 Gray 编码即是 将二进制编码通过一个变换得到的编码, 目的即为克服二进制编码中的 Hamming 悬崖的缺点。

设有二进制串  $b_1 b_2 \dots b_n$  对应的 Gray 串为  $a_1 a_2 \dots a_n$ , 则从二进制编码到 Gray 编码的变换为

$$a_i = \begin{cases} b_i, & \text{如果 } i = 1 \\ b_{i-1} \oplus b_i, & \text{如果 } i > 1 \end{cases} \quad (10)$$

其中,  $\oplus$  表示模 2 加法。

而从一个 Gray 串到二进制串的变换为

$$b_i = \sum_{j=1}^i a_j (m \text{ mod } 2) \quad (11)$$

编码: 将神经网络权值  $w_j$  编成长度为  $l$  的 Gray 代码字符串。

(2) 决定初始种群, 把神经网络的节点编号, 将连接权  $w_j$  组成一组数据, 代表一个个体, 若干个数据组构成初始种群。

(3) 适应度计算, 以神经网络的输出节点误差的网络能量函数  $e$  为基础, 选定  $F=C/e$ , 其中  $C$  为一常数,  $e$  为网络的能量函数。

(4) 根据每个个体的适应度  $F_i$ , 计算其选择概率  $P_{S_i}$ 。

$$P_{S_i} = \frac{F_i}{\sum_{i=1}^n F_i} \quad (12)$$

(5) 只用一点交叉, 但在训练中将整个 0, 1 串分成四部份: 输入层到隐含层连接权值、隐含层到输出层连接权值、隐含层阈值、输出层阈值。

(6) 变异操作, 采用基本位变异算子, 防止丢失有用的可能解, 保证算法的全局收敛, 变异概率设为 0.02。

(7) 从当前父代和子代的所有个体中选择出适应度较大的个体构成下一代群体。然后再计算适应度值, 开始了新一代的迭代。终止的条件为群体适应度趋于稳定或误差  $e$  小于某一给定值, 或已达到预定的进化代数。

## 4 算例

以成都某地区 2009 年 3、4 月实际负荷数据进行预测, 采用 24 点预测, 一共 1 464 个样本数据, 原始负荷曲线如图 1 所示, 记为  $S_t$ 。首先对电力负荷序列进行小波分解, 使分解后各小波分量具有更强的周期性和规律性。

负荷预测小波基的选择目前还没有统一的标准。这里用验证的方法选择 db4 作为小波基。为保证高次分量与低次分量充分分离, 分解层数不宜太小, 而过大的分解层数也无益于提高预测精度, 故选择为 3 层分解。

分解尺度为三, 得到分解后的各分量如图 2 所示。从图 2 中可看出小波分量  $d1$ 、 $d2$  主要表现为随




图 1 原始负荷序列 S

机性较强的非线性特征, 小波分量  $d3$  主要表现为部分随机性, 尺度分量  $a3$  主要表现了负荷的基本趋势。




图 2 原负荷序列和小波分解序列

用遗传算法优化神经网络对小波各分量进行预测, 然后进行小波重构, 最后将各分量预测结果叠加得到预测的最后结果。具体步骤如下。

① 对原始的负荷序列进行小波分解, 如图 2 所示。图中曲线清楚显示了各分量的变化趋势。

② 根据各负荷分量的特性分别建立如表 1 所示的神经网络模型,  $L(i, t)$  代表第  $i$  天  $t$  时刻的负荷值。

表 1 负荷分量特性

名称	A3模型	D3模型	D2模型	D1模型
输入	$L(i-14, t);$ $L(i-7, t);$ $L(i-2, t-1)$	$L(i-7, t);$ $L(i-2, t-12);$	$L(i-7, t);$ $L(i-1, t-18);$	$L(i-7, t);$ $L(i-1, t-18);$
样本	$L(i-2, t);$ $L(i-1, t-1)$	$L(i-2, t);$ $L(i-1, t-12);$	$L(i-1, t-12);$ $L(i-1, t-6);$	$L(i-1, t-12);$ $L(i-1, t-6);$
属性	$L(i, t-2);$ $L(i, t-1);$	前 24 时刻数据	前 24 时刻数据	前 24 时刻数据

③ 利用遗传算法优化各子序列神经网络的初始权重。

④对小波分量利用前 n 日的负荷数据直接预测第 n+1 日的一个逐时负荷, 将小波分量的数据归一化处理后进行样本训练, 得到预测结果。

⑤将预测的各分量进行小波重构, 得到负荷的预测值。

⑥相对误差

$$E = \frac{|y - \hat{y}|}{y} \quad (13)$$

用两种方法对成都某地区 4 月 18 日负荷进行预测, 数据取 20 次运行结果的平均值, 预测结果如表 2。

表 2 预测结果

预测时刻 /h:m in	实际值 /MW	小波-ANN		优化模型	
		预报值 /MW	相对误差 /%	预报值 /MW	相对误差 /%
0:00	1 505	1 504.8	-0.01	1 500.8	-0.28
1:00	1 365	1 366.8	0.13	1 366.5	0.11
2:00	1 250	1 233.5	-1.32	1 248.1	-0.15
3:00	1 303	1 284.4	-1.43	1 294.5	-0.65
4:00	1 251	1 204.6	-3.71	1 220.4	-2.45
5:00	1 197	1 194.4	-0.22	1 193.9	-0.26
6:00	1 268	1 214.1	-4.25	1 264.8	-0.25
7:00	1 422	1 439.2	1.21	1 427.0	0.35
8:00	1 408	1 414.8	0.48	1 408.7	0.05
9:00	1 628	1 636.3	0.51	1 632.1	0.25
10:00	1 697	1 697.8	0.05	1 704.1	0.42
11:00	1 681	1 670.7	-0.61	1 675.1	-0.35
12:00	1 768	1 764.5	-0.20	1 749.4	-1.05
13:00	1 554	1 530.4	-1.52	1 552.1	-0.12
14:00	1 658	1 717.0	3.56	1 658.7	0.04
15:00	1 733	1 775.5	2.45	1 734.6	0.09
16:00	1 753	1 731.6	-1.22	1 747.4	-0.32
17:00	1 833	1 923.9	4.96	1 848.4	0.84
18:00	1 791	1 774.0	-0.95	1 787.1	-0.22
19:00	1 772	1 765.6	-0.36	1 767.2	-0.27
20:00	1 958	1 957.2	-0.04	1 955.8	-0.11
21:00	1 956	1 957.4	0.07	1 956.8	0.04
22:00	1 846	1 850.6	0.25	1 844.5	-0.08
23:00	1 597	1 630.9	2.12	1 603.7	0.42
平均误差			1.32		0.38

两种方法预测一周的预测结果对比如表 3 所示, 数据取 20 次运行结果的平均值。

## 5 结 论

提出利用小波变换将负荷序列分解到不同的尺度上, 根据负荷子序列的不同特性建立相应的神经网络模型, 利用遗传算法优化选取神经网络的初始权

表 3 一周预测结果比较

日期	小波-ANN 相对误差 /%	优化模型相对误差 /%
星期一	1.32	0.38
星期二	1.45	0.54
星期三	1.68	0.62
星期四	1.55	0.76
星期五	1.40	0.65
星期六	1.28	0.50
星期日	1.38	0.68

重。通过对成都某地区的实际预测结果与未经优化的小波-神经网络模型预测结果相比较, 结果表明, 优化后的神经网络泛化能力提高, 预测精度也大为提高, 证明了该方法的正确性。

## 参考文献

- [1] 牛小东, 等. 电力负荷预测技术及其应用 [M]. 北京: 中国电力出版社, 1998.
- [2] Bo-Juen Chen, Ming-Wei Chang and Chih-Jen Lin. Load Forecasting Using Support Vector Machines: A Study on EUNITE Competition 2001 [J]. IEEE Transactions on Power Systems, 2004, 19(4): 1821-1830.
- [3] Peng T. M., Hubele N. F., Karady G. G. Advancement in the Application of Neural Networks for Short-term Load Forecasting [J]. IEEE Transactions on Power Systems, 1992, 7(1): 250-257.
- [4] 赵剑剑, 张步涵, 程时杰, 等. 一种基于径向基函数的短期负荷预测方法 [J]. 电网技术, 2003, 27(6): 22-25.
- [5] W. Charytoniuk, M. S. Chen. Neural Network Design for Short-Term Load Forecasting [C]. Conference on Electric Utility Deregulation and Restructuring and Power Technologies 2000, City University London, 4-7 April 2000, 554-561.
- [6] 徐丽娜. 神经网络控制 [M]. 哈尔滨: 哈尔滨工业大学出版社, 1999: 35-45.
- [7] 陈国良, 王煦法. 遗传算法及其应用 [M]. 北京: 人民邮电出版社, 1996.
- [8] 徐军华, 刘天琪. 基于小波分解和人工神经网络的短期负荷预测 [J]. 电网技术, 2004, 28(8): 30-33.
- [9] 邵能灵, 侯志俭, 李涛, 等. 基于小波分析的电力系统短期负荷预测方法 [J]. 中国电机工程学报, 2003, 23(1): 45-50.
- [10] 冉启文, 单永正, 王骥, 等. 电力系统短期负荷预报的小波-神经网络-PARMA 方法 [J]. 中国电机工程学报, 2003, 23(3): 38-42.
- [11] 杨延西, 刘丁. 基于小波变换和最小二乘支持向量机的短期电力负荷预测 [J]. 电网技术, 2005, 29(13): 60-64.

(下转第 67 页)

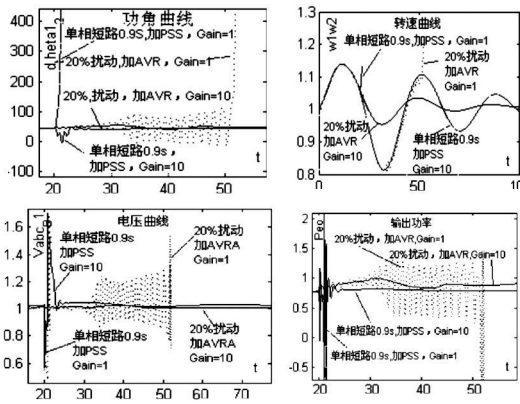


图 7 励磁电压增益仿真效果

### 3.4 线路容性补偿仿真分析

由公式可知,减小线路电抗,可以提高系统稳定极限功率,提高系统稳定性。在线路中串联电容可以达到此目的,现实中是用 TSCS 等装置来实现,本仿真中直接在线路中串联电容器来验证电容器补偿的效能。补偿度为  $\sigma = \frac{1/\omega C}{WL}$ ,仿真中用阻抗测量器分别测量补偿电容的阻抗和输电线路的阻抗,通过仿真测量得到如图 8 曲线。

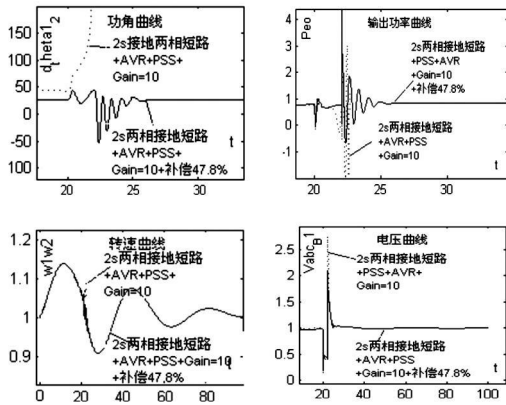


图 8 线路容性补偿仿真效果

可以看出,对 2 s 的两相接地短路这样的大扰动,即使同时加装 AVR、PSS 和 Gain=10 也不能稳定系统,当采用 47.8% 的容性补偿后,能够快速稳定系统,可见容性补偿能够大大提高系统功率极限,提高

了系统稳定性。

## 4 结 语

通过构建双机系统对励磁调节器 AVR、稳定器 PSS、励磁增益 Gain、串补电容等静态稳定性措施进行对比分析,观测系统稳定性参数功角曲线、电磁功率、母线电压、转速、极限功率等,得出了各种措施提高系统稳定性的影响力范围。励磁调节器虽然是现代发电系统必备设备,但是其稳定性能力较小,一般对 20% 范围内的小扰动有稳定能力;附加 PSS 后,稳定性大大提高,若扰动进一步增大,可适当提高发电机励磁电压增益 Gain;若扰动再增大,还可以采用线路串联电容进行容性补偿,以降低线路阻抗,提高系统稳定极限功率,提高抵抗扰动的能力。由此可见,实际中只要综合应用以上措施,可以大大提高系统稳定极限,抵抗更大的系统干扰,提高系统稳定性。

## 参考文献

- [1] 李光琦. 电力系统暂态分析 [M]. 北京: 中国电力出版社, 1995.
- [2] 赵彩宏, 田立军, 邹贵彬, 等. FCL 对电力系统暂态稳定性影响的机理分析与仿真 [J]. 电力自动化设备, 2001, 21(2): 14-17.
- [3] 吴天明. MATLAB 电力系统设计与分析 [M]. 北京: 国防工业出版社, 2004.
- [4] 袁宇春, 张保会. PSS 对电力系统动态及静态稳定性的影响 [J]. 中国电力, 1997, 30(12): 7-9.
- [5] 范影乐. MATLAB 仿真应用详解 [M]. 北京: 人民邮电出版社, 2001.
- [6] 毛钧鑫. 提高电力系统稳定运行的措施 [J]. 电气杂志 OHM, 1994, 2.
- [7] 周兆庆. MATLAB 电力系统工具箱在电力系统机电暂态仿真中的应用 [J]. 电力自动化设备, 2005, 25(4): 51-55.

(收稿日期: 2010-01-26)

(上接第 18 页)

- [12] S H. Ling, Frank H. F. Leung, H. K. Lam, Yin-Shu Lee, Peter K. S. Tam. A Novel Genetic-A Algorithm-Based Neural Network for Short-Term Load Forecasting [J]. IEEE Transactions on Industrial Electronics, 2003, 50(4): 793-799.

- [13] 梅家斌, 谢春娣. 遗传算法在神经网络权值优化中的应用 [J]. 中南民族大学学报: 自然科学版, 2001(21): 1-3

- [14] 洪露, 马长山, 谢宗安. 基于遗传算法的神经网络权值优化 [J]. 贵州工业大学学报: 自然科学版, 2003, 32(6): 48-51.

### 作者简介:

刘 绚 (1985-), 男, 硕士研究生, 研究方向为人工智能及复杂网络在电力系统中的运用。

刘天琪 (1962-), 女, 博导, 教授, 研究方向为电力系统分析计算与稳定控制、高压直流输电、调度自动化。

(收稿日期: 2010-03-19)