

电力系统短期负荷预测的级联网络模型研究

李永坚, 胡鹤宇

(湖南工程学院电气与信息工程系, 湖南 湘潭 411101)

摘要: 提出一种基于 BP 子网络和小波网络的短期负荷预测的级联网络模型。在对气象影响因素与负荷关系深入分析的基础上, 采用 BP 子网络来映射气象等不确定因素的影响。采用小波网络(预测网络)来映射历史负荷值的影响, 它结合了小波变换良好的时频局域化性质和神经网络的自学习能力, 明显地改善了神经网络难以合理确定网络结构和存在局部最优等缺陷。最后两级网络相互级联组成预测网络。研究算例表明, 这种模型是优秀的。

关键词: 负荷预测; 小波网络; 级联网络

中图分类号: TM715 **文献标识码:** A **文章编号:** 1003-4897(2004)10-0014-05

0 引言

短期负荷预测是电力系统运行和调度部门的一项重要工作。长期以来, 国内外电力工作者对负荷预测做了大量的研究。提出了许多负荷预测的方法和技术, 包括时间序列法、回归法、灰色系统法等^[1]。这些方法在解决特定的预测任务中发挥了重要作用。但在短期负荷预测中, 气象等不确定因素往往对负荷有重要影响, 而上述方法面对这些则显得无能为力。近几年来, 神经网络受到了人们的广泛关注, 它强大的多元非线性映射能力使得它能够准确捕捉负荷值与天气之间的非线性关系, 使考虑气象因素的短期负荷预测成为可能。但它也有自身无法克服的缺陷, 如难以合理确定网络结构、存在局部最优等, 并且随着网络规模的增大这些缺陷表现的越来越突出。

为了扬长避短, 本文提出一种级联网络负荷预测模型。利用神经网络善于捕捉气象因素与负荷值之间的非线性关系的特点, 第一级网络采用 BP 网络来映射气象因素的影响。第二级网络即预测网络采用小波网络。小波网络是结合小波分析理论和神经网络而形成的一种新型数学分析方法, 它兼具小波变换良好的时频局部化性质与传统神经网络的自学习功能。并且, 它引入两个新的参变量, 即尺度参数和平移参数, 所以小波网络具有更多的自由度, 从而使其具有更有效的函数逼近能力。最后将两级网络互连, 各司其职, 共同完成预测工作, 这种模型不仅能够提高效率, 缩短预测时间, 而且编制的软件易于维护、可重用性好。

1 基于气象因素影响分析的 BP 网络

神经网络主要用来映射气象因素对短期负荷的影响, 它是一个小规模 BP 网络。气象因素主要包括每日的最高气温、最低气温、平均气温、天气状况(晴、阴、雨、雪)、湿度等。

1.1 气象因素对负荷变化的影响分析

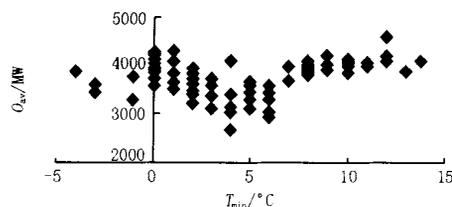
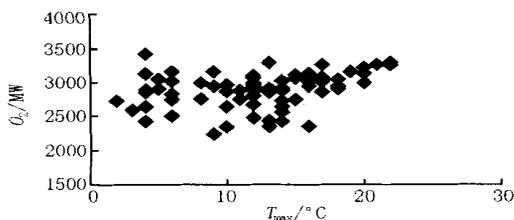
随着气象科学的发展, 气象信息预报得越来越准确, 这为我们的负荷预测带来便利。另一方面, 不同的气象信息对负荷值的影响程度并不相同。因此必须进行气象信息与负荷值之间的关联性分析。

以本文算例所用电网为例, 为了得到气象因素与负荷变化之间的关系, 我们做散点图。从图 1 可以看出: 日平均负荷 O_m 随着最低温度 T_{min} 的变化成非线性规律变化, 即 T_{min} 对 O_m 有明显的影响。从图 2 的数据分布来看, 最高气温 T_{max} 对每日 2:00 时的负荷 O_2 的影响总体上呈随机性, 即 T_{max} 对 O_2 无明显影响。同样的道理, 我们可以作其他气象因素与历史负荷值散点图(为了节省篇幅, 这些图本文从略)。从中我们可以得出结论: 最高气温、最低气温、天气状况、湿度对每日峰荷、谷荷、平均负荷有较明显的影响。因此, 为了简化模型, 提高效率, 在 BP 网络中仅考虑这四个气象信息。

需要指出的是, 在实际的预测工作中, 由于电网负荷结构不同, 所得规律也不相同, 因此应该具体问题具体分析。

1.2 神经网络的 BP 算法

神经网络确定权重的方法是 BP (Back-Propagation) 算法。有关 BP 算法用于负荷预测的文献较多(如[4, 8]), 在此不再赘述。

图1 (T_{\min}, O_{av}) 散点图Fig. 1 Diagram of (T_{\min}, O_{av}) scatter points图2 (T_{\max}, O_2) 散点图Fig. 2 Diagram of (T_{\max}, O_2) scatter points

2 小波网络

小波网络是以一族小波基代替 Sigmoid 函数而构成的一种新型函数连接网络。它通过将小波基与信号向量的内积进行加权和来实现信号的特征提取。

2.1 小波网络对神经网络缺陷的改善

小波网络对神经网络难以合理确定网络结构等缺陷进行了有效的改善。在实际设计小波网络的过程中,我们充分利用小波具有的时频局部化性质,设计网络的基本依据是:对于小规模(高频)特征信号的空间局部区域的识别,小波是很合适的^[31]。因此,在某一规模(伸缩)上的小波近似系数的局部最大值表明:是否需要通过使用在较小规模的小波来局部精确近似。本文中,隐含层处理单元数目采用如下步骤进行确定:

1) 构造一个小波网络,使其在训练集上达到近似映射;

2) 识别小波系数的局部极大,在需要的地方加入新的伸缩(处理单元)来局部精确近似;

3) 重复 2),直到终止标准被满足。

上述步骤的原理示意图如图 3 所示。

横轴 t 是时间轴,纵轴 w 是频率轴。 Q_f 表示训练数据所占有的时频域,各个黑点代表各个小波时频窗的中心。低频小波表现 Q_f 的“概貌”,高频小波表现 Q_f 的“细节”。因此,最优的隐含层处理单元个数应该等于被 Q_f 覆盖的黑点的个数。这也为小波网络确定网络结构提供了理论支持。

另外,作为小波公式的结果,所确定的权在网络

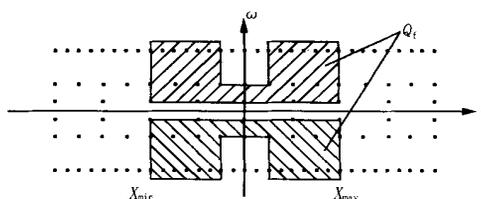


图3 网络设计原理图

Fig. 3 Diagram of WNN design

的输出方程中呈线性,这样误差函数 E 是权重 W_i 的凸函数,网络的训练是对特定凸函数的优化过程^[31]。

2.2 小波网络模型

信号 O_m 的小波变换如式(1)所示:

$$W_f(a, b) = \int_R O_m \overline{\psi_{ab}}(t) dt \quad (1)$$

其中: $\psi_{ab}(t)$ 称为小波函数,简称小波,表达式如下:

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

它是由母小波 $\psi(t)$ 经平移与放缩的结果, $\psi(t)$ 需满足条件:

$$\int_R \psi(t) dt = 0 \quad (3)$$

$$\int |\psi(t)|^2 dt < \infty \quad (4)$$

式(3)说明 $\psi(t)$ 具有波动性,式(4)说明 $\psi(t)$ 具有紧支性(在有限区间外恒等于 0 或者很快地趋近于 0),因此 $\psi(t)$ 是象波一样快速衰减的函数,这就是小波名称的由来。式(2)中 a 称为伸缩因子,它的改变会引起小波窗口大小与形态的改变; b 称为平移因子,它的改变会引起小波窗口位置的改变。

在绝大多数用于负荷预测的神经网络中,S 形函数被前传网络充当函数近似的基。然而由于缺乏适当的理论框架,前传神经网络的拓扑学的定义在许多地方已经露出构造的痕迹和错误。小波网络以一组小波基取代神经网络中的 S 形函数,如前所述,小波基中含有伸缩因子和平移因子,通过调整他们的大小就可以改变小波窗口的大小、位置与形态,而这种调整在小波网络的训练过程中是自适应的。因此,小波网络具有比神经网络更精确、更灵活有效的函数逼近能力。

基于上述分析,当我们选择紧支集正交小波时,信号可以用一族小波进行叠加来逼近,即:

$$O_m = \sum_{k=1}^K w_k \left(\frac{\sum_{i=1}^N u_{ki} x_n(i) - b_k}{a_k} \right) \quad (5)$$

式(5)可以用图4所示的小波网络来描述,其中取 Morlet 小波,其表达式是:

$$(t) = \cos(1.75 t) \exp(-\frac{t^2}{2}) \quad (6)$$

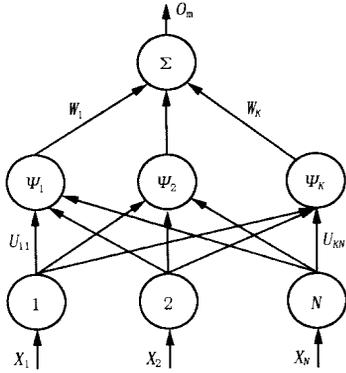


图4 小波网络结构

Fig.4 Structure of WNN

2.3 小波网络的学习算法

求解权重的方法采用梯度下降法。误差函数为:

$$E = \frac{1}{2} \sum_{m=1}^M (t_m - o_m)^2 \quad (7)$$

式(7)中 o_m 、 t_m 表示给定训练模式下的训练输出和目标输出。算法的流程框图如图5所示。其中:

$$w_k = - \frac{\partial E}{\partial w_k} + w_k \quad (8)$$

$$u_{ki} = - \frac{\partial E}{\partial u_{ki}} + u_{ki} \quad (9)$$

$$a_k = - \frac{\partial E}{\partial a_k} + a_k \quad (10)$$

$$b_k = - \frac{\partial E}{\partial b_k} + b_k \quad (11)$$

在式(8)、(9)、(10)、(11)中:

$$\frac{\partial E}{\partial w_k} = - \sum_{m=1}^M (t_m - o_m) \left(\frac{\sum_{i=1}^N u_{ki} x_n(i) - b_k}{a_k} \right) \quad (12)$$

$$\frac{\partial E}{\partial b_k} = - \sum_{m=1}^M (t_m - o_m) w_k \frac{\partial}{\partial b_k} \quad (13)$$

$$\frac{\partial}{\partial b_k} = \frac{1.75}{a_k} \sin(1.75 t_n) \exp(-\frac{t_n^2}{2}) + \frac{t_n}{a_k} \cos(1.75 t_n) \exp(-\frac{t_n^2}{2}) \quad (14)$$

$$\frac{\partial E}{\partial u_{ki}} = - \sum_{m=1}^M (t_m - o_m) w_k x_n(i) \frac{\partial}{\partial u_{ki}} \quad (15)$$

$$\frac{\partial}{\partial u_{ki}} = - \frac{1.75}{a_k} \sin(1.75 t_n) \exp(-\frac{t_n^2}{2}) - \frac{t_n}{a_k} \cos(1.75 t_n) \exp(-\frac{t_n^2}{2}) \quad (16)$$

$$\frac{\partial E}{\partial a_k} = - \sum_{m=1}^M (t_m - o_m) w_k \frac{\partial}{\partial a_k} \quad (17)$$

$$\frac{\partial}{\partial a_k} = \frac{1.75 t_n}{a_k} \sin(1.75 t_n) \exp(-\frac{t_n^2}{2}) + \frac{t_n^2}{a_k} \cos(1.75 t_n) \exp(-\frac{t_n^2}{2}) \quad (18)$$

在上面诸式中: $t_n = \frac{\sum_{i=1}^N u_{ki} x_n(i) - b_k}{a_k}$ 。、 分别是学习速度和惯性常数。

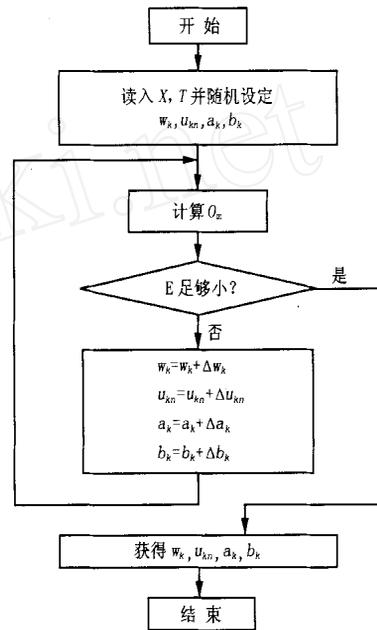


图5 BP算法流程图

Fig.5 Flow chart of BP algorithm

3 级联网络 —— 预测模型

基于以上的分析,建立如图6所示基于BP&WNN级联网络预测模型。本模型采用逐个负荷点分别预测的方式。模型输入量的选择应当遵循“近大远小”的原则,即离预测点越远,对预测点负荷值的影响越不明显。实验表明,选取图6所示的输入量即能够满足精度要求,并且网络结构最为简洁。

图6中 O, T, W, H 分别代表负荷值、温度、天气状况以及湿度;下标 max, min, av, i 分别表示最大、最小、平均和 i 时刻的负荷值;上标 $d, d-1, d-2$ 分别表示预测日,预测日前一天及预测日前两

天。

另外,如图6所示,BP神经网络的结构为 $14 \times 8 \times 3$,它是一个小规模神经网络,训练速度很快,并且BP网络的输出为预测日的最大负荷、最小负荷及平均负荷,即用BP神经网络大致给出了预测日的负荷水平,因此这不仅不会产生所谓的“误差积累”效应,相反有助于预测精度的提高。

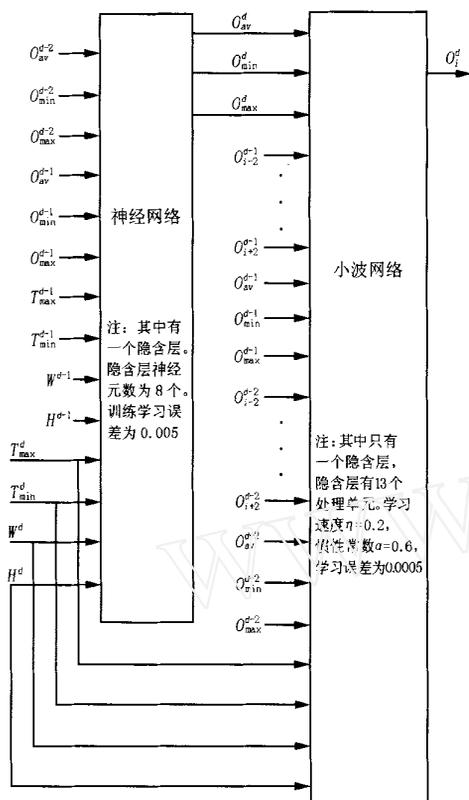


图6 级联网络预测模型框图

Fig. 6 Block diagram of cascaded networks forecasting model

4 算例研究

以某省电力系统实际历史负荷为例,系统平均负荷约为4.5 GW,为水火电并容系统,气象条件影响很大,用上述模型对该省负荷进行了预测。表1给出了预测结果。其中误差的评价指标采用国际上比较常用的平均绝对误差MAPE(Mean Absolute Percentage Error)和均方根误差RMSE(Root Mean Squared Error)。计算公式分别如下:

$$\text{MAPE} = \frac{1}{24} \times \sum_{i=1}^{24} \left| \frac{t_i - o_i}{t_i} \right| \times 100$$

$$\text{RMSE} = \sqrt{\frac{1}{24} \sum_{i=1}^{24} (t_i - o_i)^2} \times 100$$

上式中 o_i 、 t_i 分别代表预测值和实际值。图7对其中一日负荷的实际值和预测值进行了对照,其中实线是实际的负荷曲线,虚线是预测的负荷曲线。从预测结果来看,本文采用的级联网络预测模型也是一种可行的预测方案。由表1和表2我们可以看出,几个关键的误差评价指标都得到了较大的提高。在对模型的训练过程中我们还发现,在相同的训练模式下,本文模型的收敛速度高于ANN。但是必须指出,小波网络参数的初始值的选取对网络训练有较大的影响,选取不当也可能会造成收敛速度缓慢的情况。图7反映出,每日24点负荷的预测值不仅与实际值吻合的很好,而且也具有较大的关联度。

表1 某省电网级联网络模型预测结果

Tab. 1 Load forecasting results based on cascaded network model

	峰值负荷预测误差 / (%)	RMSE / (%)	MAPE / (%)
97.2.18	1.201	3.064	2.572
97.2.19	-1.830	2.481	2.101
97.2.20	-2.004	3.294	1.927
97.2.21	1.922	3.649	2.806

表2 某省电网ANN模型预测结果

Tab. 2 Load forecasting results based on ANN model

	峰值负荷预测误差 / (%)	RMSE / (%)	MAPE / (%)
97.2.18	1.412	3.443	2.703
97.2.19	-1.679	2.509	2.081
97.2.20	-2.897	3.505	2.141
97.2.21	2.143	3.730	2.985

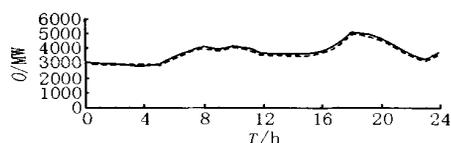


图7 2.19日负荷预测曲线

Fig. 7 Forecasted load curve on Feb. 19th

5 结论与展望

电力系统短期负荷预测是一项十分复杂的工作。本文介绍的级联网络模型,有以下优点:

1) 将影响短期负荷变化的主要因素,即气象因素和历史负荷值分开考虑,既提高了模型的效率,又避免了众多影响因素同时输入网络而造成淹没。

2) 预测网络即小波网络不仅具有更好的特征提取和屏蔽随机噪声的能力,并且改善了神经网络

难以确定网络结构、存在局部最优等缺陷,进一步提高了预测的精度。小波理论虽然为确定小波网络的结构提供了坚实的理论基础,但是在电力系统的应用还不很成熟,确定网络结构仍然是一项很繁琐的工作,需要在实践中寻找更加简洁有效的方法。此外,不同的小波基有可能缩短学习时间和提高预测精度,因此可以尝试使用不同的小波基。

参考文献:

- [1] 徐长发,李国宽(XU Changfa, LI Guo-kuan). 实用小波方法(Practical Wavelet Method) [M]. 武汉:华中科技大学出版社(Wuhan: Huazhong University of Science and Technology Press), 2001.
- [2] 牛东晓,曹树华,赵磊,等(NIU Dong-xiao, CAO Shu-hua, ZHAO Lei, et al). 电力负荷预测技术及其应用(The Technology of Power Load Forecasting and Its Application) [M]. 北京:中国电力出版社(Beijing:China Electric Power Press), 1998.
- [3] 李建平(LI Jianping). 小波分析与信号处理(Wavelet Analysis and Signal Processing) [M]. 重庆:重庆出版社(Chongqing:Chongqing Press), 1997.
- [4] Alfuhaid A S. Cascaded Artificial Neural Network for Short term Load Forecasting [J]. IEEE Trans on Power Systems, 1997, 2(11):1524.
- [5] GUO Qing-xiang, LIU Lei, et al. Driving Force Prediction for Inclusion Complexation of α -cyclodextrin with Benzene Derivatives by a Wavelet Neural Network [J]. Chemical Physics Letters, 1998, 290:514-518.
- [6] YAO S J, SONG Y H, et al. Wavelet Transform and Neural Networks for Short-term Electrical Load Forecasting [J]. Energy Conversion & Management 2000, 41:1975-1988.
- [7] ZHANG Hong-bo, ZHANG Jun, et al. The Discrete Wavelet Neural Network and Its Application in Oscillographic Chronopotentiometric Determination [J]. Chemometrics and Intelligent Laboratory Systems, 2001, 59:67-74.
- [8] KIM Kwang-ho, YOUN Hyoung-sun, et al. Short-term Load Forecasting for Special Days in Anomalous Load Conditions Using Neural Networks and Fuzzy Inference Method [J]. IEEE Trans on Power Systems, 2000, 15(2).
- [9] CHAU Tom. A Review of Analytical Techniques for Gait Data, Part 1: Neural Network and Wavelet Methods [J]. Gait and Posture, 2001, 13:102-120.

收稿日期: 2003-09-02; 修回日期: 2003-11-19

作者简介:

李永坚(1971-),男,讲师,硕士研究生,研究方向为电力系统与电气工程及其自动化;

胡鹤宇(1972-),男,实验师,研究方向为电气工程及其自动化。

Research on cascaded network model for short-term load forecasting in power system

LI Yong-jian, HU He-yu

(Hunan Institute of Engineering, Xiangtan 411101, China)

Abstract: This paper proposes a cascaded network model based on BP subnetwork and WNN(wavelet neural network) for short-term load forecasting. The influence of uncertain factors such as climate is mapped through BP subnetwork based on the analysis of the relationship between the climatic factor and load data. Since WNN combines the time-frequency localization characteristic of wavelet and its self-learning ability, the influence of historical data is mapped through WNN, which helps to overcome the defects of ANN such as the difficulty of rationally determining the network structure and the existence of partial optimal points. Finally, the two subnetworks are combined to form the cascaded forecasting network. The results of the experimental research show that this method is superior.

Key words: short-term load forecasting; wavelet neural network(WNN); cascaded network

三峡工程 8 台机组投产 日发电量过亿度

2004年4月30日8:30,长江三峡工程左岸电站7号发电机组在完成各项运行试验和例行检查后,正式并网发电。至此,三峡工程已有8台70万kW大型机组投产,日发电量达1.15亿kWh。机组从总装到完成72h试运行仅用了59天,实现了一次安装成功、一次试验成功、一次启动成功,是三峡投产机组中安装调试工期最短的机组。按照设计,三峡工程将安装26台70万kW水轮发电机组,机组全部投产后年平均发电量为847亿kWh。根据三峡工程建设计划,2004年三峡工程将有4台机组投产。今年首台投产机组已在4月7日正式并网发电,7月和9月还将有两台机组投产。