

# 基于 RBF 神经网络的短期负荷预测模型设计

俞秋阳, 朱 斌, 郭 伟

(东南大学电气工程系, 江苏 南京 210096)

摘要: 在分析了某地区日平均负荷曲线的年周期性、周周期性、日周期性的基础上提出了每日 24 个整点负荷值的分段预测模型。根据该模型建立相应的 RBF 神经网络进行预测。并将预测结果与实际负荷值、由传统的 BP 网络模型得到的结果分别进行了对比分析, 表明这种模型结合 RBF 神经网络的预测效果具有较高的精度, 具备了一定的实用价值。

关键词: 短期负荷预测; 人工神经网络; 径向基函数

中图分类号: TM715 文献标识码: A 文章编号: 1003-4897(2004)17-0034-04

## 0 引言

随着电力改革的逐步深入和电力市场的初步建立, 电力系统短期负荷预测的重要性也日渐显现。无论是电网的安全、经济运行, 发电公司的上网报价, 还是供电公司的购电计划等都与此密切相关。因此, 迫切需要在传统方法的基础上, 深入分析某一地区的负荷特性, 探求高精度的预测模型和预测方法, 以满足电力市场条件下负荷预测的新要求。

## 1 地区负荷特性分析

本文首先以泰州地区 1999 和 2000 年度全年日平均负荷数据为蓝本分析了该地区一年之中日平均负荷的变化趋势。从图 1 中可以观察到泰州地区日平均负荷的年变化趋势具有以下特点: 各季节负荷分布不均匀; 夏、冬季负荷比春、秋季负荷高; 夏季负荷与冬季负荷之间没有确定的大小关系。泰州地处长江中下游地区, 四季分明, 夏季的制冷负荷、冬季的取暖负荷都较为明显, 这些特点正好与负荷的年变化趋势相对应, 可见电力负荷与当地气候类型密切相关。此外, 特殊长假的电力负荷下降明显, 尤以春节最为显著。同时该地区负荷呈现出整体增长的趋势, 从 2000 年的秋季开始, 负荷与 1999 年同期相比有较大幅度增长, 这与该地区撤地建市后城市建设快速发展相吻合。

然后本文以 1999 年 3 月 22 日至 5 月 2 日春季 6 周和 1999 年 7 月 19 日至 8 月 29 日夏季 6 周的数据为蓝本对日平均负荷的周变化趋势做了分析。从图 2 可以看出, 泰州地区负荷的周变化趋势并不十分明显, 周六、周日与工作日相比负荷的减少有限。因此可得出该地区工业用负荷比重较大, 一周内的

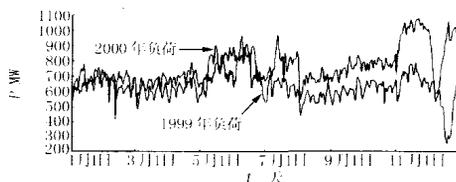


图 1 1999、2000 年度日平均负荷变化曲线

Fig. 1 Daily average load curves in 1999 and 2000

负荷情况与气候因素强相关的结论。

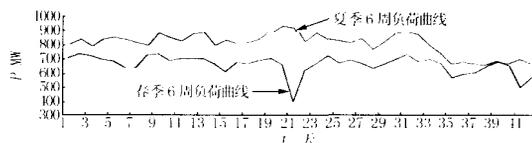


图 2 日平均负荷周变化曲线

Fig. 2 Daily average load curves in a week

最后, 本文绘制了泰州地区 2000 年 4 月中一周内 (4 月 12 日至 4 月 18 日) 每日的整点负荷曲线 (图 3), 从中可以分析负荷变化的日周期性。从图上可以看出, 电力负荷的日周期性十分明显, 大致呈现出一个 M 形, 即存在我们通常所说的日峰、晚峰和日谷。

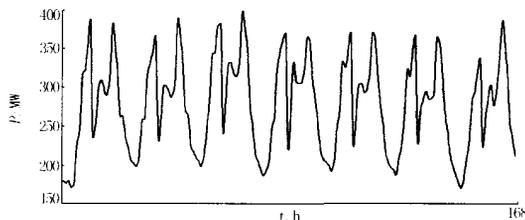


图 3 2000 年 4 月 12 日至 4 月 18 日每日整点负荷曲线

Fig. 3 Hourly load curve from Apr. 12 to Apr. 18 in 2000

通过以上的分析可以总结出该地区的负荷特性:

- 1) 电力负荷随季节变化,周周期性不是十分的显著,日周期性则十分明显;
- 2) 气候因素对日负荷的影响较大;
- 3) 节假日电力负荷的变化显著;
- 4) 该地区工业用负荷较大。

## 2 预测模型设计

电力负荷预测的方法很多<sup>[1]</sup>,例如外推预测技术、回归模型预测技术、时间序列预测技术,以及近年来发展和成熟起来的灰色系统、专家系统、神经网络、小波分析等方法。其中用于短期负荷预测效果较好的方法有属于回归模型的 ARMA 方法(自回归移动平均法)和神经网络方法<sup>[2]</sup>。神经网络方法可以处理负荷与各个影响因素之间复杂的非线性关系,预测精度高,因此受到了广泛的关注,并得到了大量的工程应用。本文将采用以基于径向基函数的 RBF 神经网络作为泰州地区短期负荷的预测方法。这种神经网络的特点,下文将有所论述。

将神经网络用于负荷预测的关键之处在于,应根据负荷特点建立合适的网络结构,控制神经元节点的数量,加快收敛速度,以达到较好的预测效果。考虑到短期负荷预测可用的训练样本容量有限,如果同时预测每日 24 个整点负荷,那么神经网络的规模将比较庞大,对算法的收敛性和预测的精度产生不良的影响。<sup>[3]</sup>所以本文在建立网络结构以前,首先对每日的负荷特性分段进行了研究,建立了相应的模型,以期达到较好的预测效果。下面对此做一个简要的论述。

根据图 3 可以找出每天负荷的几个转折点,分别为:4 点、11 点、15 点、17 点、19 点。因此可以将每日负荷的变化分为几个时段:1 点至 4 点、4 点至 11 点、12 点至 15 点、15 点至 17 点、17 点至 19 点、19 点至 24 点,共 6 个特征时段。研究表明对于以上六个时段,每个时段的负荷具有极大的相似性和固定的趋势,不同时段的负荷其概率意义上的相关性不明显,这一点可以用时间序列理论中的自相关系数进行验证。鉴于此,本文针对 6 个时段的负荷分别建立相应的神经网络。在负荷趋势的转折点:即 4 点、15 点、17 点、19 点的预测值采用平均值。日负荷分段的模型,减小了神经网络的规模,降低了训练的难度,某种程度上将工业负荷和民用负荷加以区分,电力负荷对气象条件的依赖性也被粗线条地划分,这样就会取得较好的预测效果。

同时考虑到泰州地区负荷的周周期性并不明

显,因此对神经网络的组织结构有如下考虑:将一天分为 6 个时段,建立各自的 RBF 神经网络。向每一个网络输入前一天相应时段的负荷数据、前一天的最高气温、最低气温、当天的最高气温、最低气温,则该网络就会输出当天同时段的整点负荷预测值。

接下来以第一时段,即凌晨 1 点到 4 点为例,来说明如何选择训练样本:用待预测日前四天相应时段的负荷值及气象数据形成 3 个训练样本,其输入输出变量的定义如表 1 所示:

表 1 输出/输入变量定义

样本号	输入变量		输出变量	
1	$L_{-4}^{4 \times 1}$	$T_{-4}^{2 \times 1}$	$T_{-3}^{2 \times 1}$	$L_{-3}^{4 \times 1}$
2	$L_{-3}^{4 \times 1}$	$T_{-3}^{2 \times 1}$	$T_{-2}^{2 \times 1}$	$L_{-2}^{4 \times 1}$
3	$L_{-2}^{4 \times 1}$	$T_{-2}^{2 \times 1}$	$T_{-1}^{2 \times 1}$	$L_{-1}^{4 \times 1}$

其中  $L_{-4}^{4 \times 1}$  代表四天前 1 点到 4 点的整点负荷值,下标 -4 表示其为四天前的数据,上标表示其为 4 维列向量;  $T_{-4}^{2 \times 1}$  代表四天前日最高气温和最低气温;  $T_{-3}^{2 \times 1}$  代表三天前的日最高气温和最低气温,上、下标的含义同上,这组输入样本对应的输出是  $L_{-3}^{4 \times 1}$ ,即三天前 1 点到 4 点的整点负荷值。其他样本以此类推。那么预测当天的 1 点至 4 点的整点负荷,则需要输入昨天 1 点至 4 点的负荷值,以及昨天和今天的日最高最低气温。其他时段预测模型的设计方法以此类推。

综上,该地区短期负荷预测共采用了分时段的 6 个 RBF 神经网络模型。最后将六个网络的预测结果组合得到当天的 24 整点负荷数据。

## 3 RBF 神经网络模型

下面简要介绍一下本文所采用的径向基函数(RBF)神经网络。

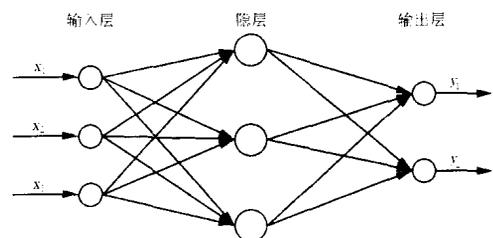


图 4 RBF 网络

Fig. 4 RBF network

RBF 神经网络通常是一种两层前向网络,其结构如图 4 所示。输入层节点将信号传递到隐层节点,隐层节点也称 RBF 节点,一般由像高斯核函数那样的辐射状传递函数构成。输出层节点的输出则

由隐层节点所给出的非线性基函数经过线性组合而得到。输入信号在隐层节点传递函数(核函数)的作用下产生局部响应,当输入信号的值接近径向核函数的中央点时,隐层节点将产生较大的输出。这种网络具有较强的局部逼近能力,因此径向基函数网络也称为局部感知场网络。

图 5 是径向基网络的隐层神经元示意图。

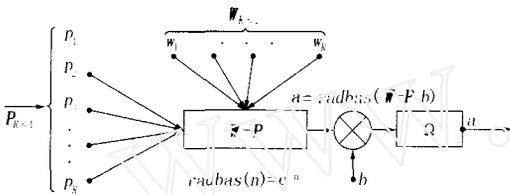


图 5 隐层神经元

Fig. 5 Neuron in hidden layer

每个径向基神经元的输入向量  $P$  与权向量  $W$  的距离乘以权  $b$  以后输入至径向基函数  $radbas()$ 。

作为基函数的函数形式有以下几种:

$$f(x) = \exp[-(x/\sigma)^2]$$

$$f(x) = \frac{1}{(2 + x^2)}, \quad x > 0$$

$$f(x) = (2 + x^2)^{-1}, \quad x < 0 < 1$$

上面这些函数都是径向对称的,本文采用高斯核函数(Gaussian kernel function),如下式所示:

$$u_j = \exp\left[-\frac{(X - C_j)^T(X - C_j)}{2\sigma_j^2}\right], \quad j = 1, 2, \dots, N_h$$

其中,  $u_j$  是第  $j$  个隐层节点的输出,  $X = (x_1, x_2, \dots, x_n)^T$  是输入样本,  $C_j$  是高斯函数的中心值,  $\sigma_j$  是标准化常数,  $N_h$  是隐层节点数。由上式可知,节点的输出范围在 0 和 1 之间,且输入样本愈靠近节点的中心值,输出愈大。

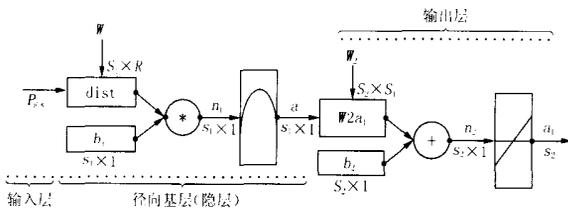


图 6 RBF 神经网络详细结构

Fig. 6 Structure of RBF neural network

图 6 是整个 RBF 网络的详细结构:  $R$  维的输入向量输入至隐层  $s_1$  个节点中,分别与其中的权向量计算距离乘上权因子  $b$  后送入各个神经元的径向基函数,输出后送往线性输出层进行线性组合,从而得到结果。

本文的 RBF 神经网络采用自适应的学习算法,即学习过程分为两个阶段:根据所用的样本确定隐层 RBF 节点的数目及参数,每次迭代增加一个节点,主要确定每个高斯核函数的中心值  $C_j$  和标准化常数  $\sigma_j$ ;第二阶段,在决定好隐层的参数后,根据样本,利用最小二乘原则,求出输出层的参数。

径向基函数(RBF)神经网络与常用的采用误差反向传播算法(BP 算法)的神经网络模型相比具有以下优越性:BP 网络用于函数逼近时,权值的调整采用的是负梯度下降法,这种调节权值的方法有它的局限性,即存在着收敛速度慢和容易陷于局部值极小的缺点,而径向基函数网络无论在逼近能力、分类能力和学习速度等方面均优于 BP 网络。从理论上讲,RBF 网络和 BP 网络一样可以逼近任意的连续非线性函数。两者的主要差别在于各使用不同的作用函数,BP 网络中的隐层节点使用的是 Sigmoid 函数,其函数值在输入空间中无限大的范围内为非零值,而 RBF 网络中的作用函数则是局部的。

#### 4 预测结果对比分析

利用上文提出的基于 RBF 神经网络的短期负荷预测模型,我们选取泰州地区 1999 年 4 月 11 日至 4 月 18 日这一周的每日整点负荷作为测试数据,对 4 月 16 日(周五)的 24 个整点负荷值进行了预测。预测的结果与实际的负荷曲线对比如图 7 所示。

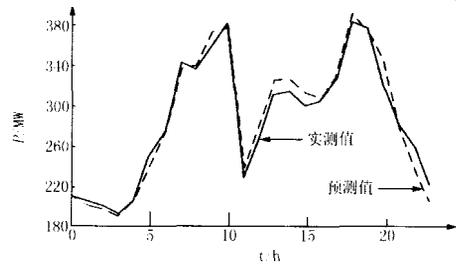


图 7 预测曲线与实际曲线

Fig. 7 Forecasting curve vs actual curve

其中实线代表的是实际负荷,而虚线则是根据预测值绘制的负荷曲线,通过粗略的观察可以看出两者有很好的吻合度。为了量化预测值的准确程度,本文使用预测日整点的百分比误差,其定义为:

$$= \frac{|y_i - \hat{y}_i|}{\hat{y}_i} \times 100\%$$

式中:  $y_i$  和  $\hat{y}_i$  分别表示第  $i$  小时的预测负荷值和实际负荷值。为了衡量本文提出的 RBF 网络分时段预测模型的预测效果,我们用传统的 BP 网络同时预测 24 个整点负荷,然后将两种方法得出的预测值做

了比较,结果如表 2 所示:

表 2 两种模型预测误差对比

时间	RBF 网络分段模型/(%)	BP 网络/(%)
1	1.66	0.22
2	1.71	1.89
3	1.85	1.59
4	1.17	1.23
5	0.16	0.93
6	0.42	4.5
7	1.88	0.11
8	2.98	1.72
9	2.94	1.03
10	2.12	3.18
11	0.64	1.24
12	1.41	2.41
13	2.56	4.49
14	4.67	4.11
15	1.43	3.87
16	2.94	3.62
17	0.32	0.82
18	0.68	0.25
19	1.82	2.06
20	0.15	0.99
21	4.78	6.76
22	0.31	1.76
23	1.75	7.87
24	1.02	6.46
平均	1.72	2.63

从表 2 可以看出,采用本文提出的模型,对该地区负荷的预测结果要明显好于传统的 BP 算法,且平均误差大大低于 5% 的标准,一定程度上达到了实用化的要求。

## 5 结束语

从泰州地区负荷预测的实例中,可以得到以下几点经验:使用人工神经网络的方法进行短期负荷预测的关键在于,要根据本地负荷的特点设计好网络的结构。因此首先要对负荷的年趋势、周趋势、日趋势进行详细的分析,针对其特点设计相应的预测模型。本文就该地区的负荷特性建立了分段预测的

模型。RBF 神经网络用于这种模型,其预测的效果要好于传统的 BP 网络。希望我们的工作能对人工神经网络在电力系统负荷预测中的应用起到一定的推进作用。

## 参考文献:

- [1] 牛东晓,曹树华,等(NIU Dong-xiao,CAO Shu-hua,et al). 电力负荷预测技术及其应用(Forecasting Technology of Power Load and Its Application)[M]. 北京:中国电力出版社(Beijing:China Electric Power Press),1998.
- [2] 高辉清,孙卫东,译(GAO Hui-qing, SUN Wei-dong, Trans). 人工神经网络预测和决策模型(Forecasting and Decision Model of Artificial Neural Network)[J]. 预测(Forecasting),1995,(4).
- [3] 李鹏,任震(LI Peng, REN Zhen). 广州电网负荷特性分析及短期负荷预测模型设计(Guangzhou Regional Load Analysis and Short Term Forecasting Model Design)[J]. 电力自动化设备(Electric Power Automation Equipment),2002,22(8):50-53.
- [4] 高山,单渊达(GAO Shan, SHAN Yuan-da). 基于径向基函数网络的短期负荷预测(A New Short-term Load Forecasting Algorithm Based on Radial Basis Function Network)[J]. 电力系统自动化(Automation of Electric Power Systems),1999,23(5):31-34.
- [5] 鞠平,姜巍,等(JU Ping, JIANG Wei, et al). 96 点短期负荷预测方法及应用(Ninety-six Points Short-term Load Forecasting Theory and Applications)[J]. 电力系统自动化(Automation of Electric Power Systems),2001,25(22):32-36.

收稿日期: 2003-12-11; 修回日期: 2004-02-04

作者简介:

俞秋阳(1980-),男,硕士研究生,研究方向为电力系统无功电压控制;E-mail: fallsunplus@mail.china.com

朱斌(1968-),男,硕士研究生,研究方向为电力市场及电力需求侧管理;

郭伟(1970-),男,副教授,硕士生导师,研究方向为电力系统稳定与控制。

## Short term load forecasting based on RBF neural network

YU Qiu-yang, ZHU Bin, GUO Wei

(Dept of Electrical Engineering, Southeast University, Nanjing 210096, China)

**Abstract:** This paper analyses the characteristic of load curve in certain area and introduces a new model to forecast the load value of every hour in the next day. RBF neural network used in the model and the implementation of the network are described and compared with the traditional BP network. The numerical results are presented to show the efficiency and accuracy of the model. This can be a useful method to artificial neural network short-term load forecasting.

**Key words:** short-term load forecasting; artificial neural network; radial basis function