

# 基于主成分分析 L-M 神经网络高峰负荷预测研究

柳进, 唐降龙

(哈尔滨工业大学, 黑龙江 哈尔滨 150001)

**摘要:** 在论述电网高峰负荷预测重要性和特点的基础上, 将高峰负荷样本, 按节气工作日和节假日样本进行聚类, 从输入空间入手, 采用主成分分析法, 减少输入向量的维数, 并保留原来输入向量的有用信息, 再利用 L-M 优化算法的多层神经网络预测模型对辽宁电网高峰负荷进行了模拟预测, 预测精度令人满意。

**关键词:** 高峰负荷预测; 运行模式; 主成分分析; 神经网络

**中图分类号:** TM715 **文献标识码:** A **文章编号:** 1003-4897(2004)13-0024-04

## 0 引言

去年和今年夏季负荷高峰时期, 我国许多电网处于高度紧张状态。多年销声匿迹的“拉闸限电”, 又呈现卷土重来之势。今年入夏以后, 北美东部系统又发生有史以来规模最大的“8.14”大停电。接着, 英国伦敦电网在8月28日高峰期也发生事故, 50万人被困地铁半小时。此后在欧洲发生的意大利等国电网停电事故, 规模都不小。由于空调等负荷的快速增长, 电网夏季高峰负荷期间, 电网供需矛盾尖锐, 此时一有风吹草动, 很容易引发灾害性的大面积停电。从贯彻电网运行“安全、优质、经济”原则和防灾减灾的角度看, 及时开展高峰负荷预测研究很有必要。“凡事预则立”, 高峰预测是电网调度中心进行正确调控决策的必要条件。文献[1]提出了一种提高电网攀峰响应能力的调控策略, 但要想这种调控策略奏效, 必须有一定精确度的高峰负荷预测作为前提条件。如果对某一次不寻常的高峰负荷未能准确预报, 那么电网调度中心就不能及时给电网预备充足而又不过量的攀峰响应能力。这容易丧失主动权, 导致险象环生, 甚至发生严重事故。

随着计算机信息技术的发展, 神经网络技术已具有并行处理、自组织学习、自适应和高度的非线性映射的特征, 它常在负荷预测中用来实现非线性拟合预测的功能, 但一般的BP算法收敛速度很慢, 而L-M(Levenberg-Marquardt)结合了梯度下降法和Gauss-Newton法的优点, 在网络权值数目较小时收敛非常迅速, 使学习时间明显缩短<sup>[2]</sup>。因此, 本文在分析高峰负荷预测特点的基础上, 提出了基于主成分分析L-M数值优化算法的多层神经网络高峰负荷预测方法, 该方法将高峰负荷样本, 按节气工作日和节假日样本进行聚类, 从输入空间入手, 采

用主成分分析法<sup>[3]</sup>, 把维数较多的输入向量经过线性变换后得到维数较少的新输入向量, 且分量间相互独立, 并保留原来输入向量的有用信息, 再利用L-M数值优化的多层神经网络预测模型算法编制的软件, 进行辽宁电网高峰实际负荷数据的模拟预测, 不仅对普通工作日有较高的预测精度, 对节假日也有较好的预测精度。

## 1 高峰负荷预测的特点

高峰负荷预测是为电网调峰、调频和安全运行服务的, 由于其这一宗旨, 它应该具有与一般短期负荷预测不同的特点:

(a) 高峰负荷预测作为一种超短期预测, 它采用持续时间较短的时段。短期负荷预测一般采用持续时间为1h的时段, 也有采用持续时间为半小时或一刻钟的情况; 而高峰负荷预测一般采用持续时间为5min的时段, 从动态优化调度的角度观察, 5min一个时段属于在线调度级, 发电机组输出功率升降速率一般是按每分钟多少兆瓦来计算的。在空调负荷快速增长的情况下, 高峰负荷曲线前沿陡升段负荷增长的速率很快, 有可能达到每分钟1%负荷峰值。在这种情况下, 一个时段(5min)负荷增长量为数就会相当大, 需要认真对待。

(b) 对于高峰负荷曲线不同区段, 在精度要求上, 不应平均对待, 而要突出重点。对高峰负荷曲线前沿区段, 特别是陡升段落, 精度要求较其它区段高, 这是因为在前沿高位陡升段落, 机组输出功率处于或接近上限, 缺乏上行调节余量。为了保证调度中心在高峰负荷来临前, 及时为电网预备充足而又不过量的攀峰响应能力, 需要对前沿区段提高预测精度要求。不但对前沿区段各个时刻负荷数值有精度要求, 而且对各个时刻负荷的增长速率以及负荷

高位陡升开始的时刻都应有精度要求,这与一般负荷预测有十分明显的区别。

(c) 从模式分析角度考察,高峰负荷样本除了有工作日相关性和节假日相关性外,还有较明显的节气相关性。对于一年 24 个节气,高峰负荷预测工作将冷热两头作为重点,冷的一头以冬至、小寒和大寒三个节气为主体,考虑立春以后还会有春寒;热的一头以夏至、小暑和大暑三个节气为主体,考虑立秋以后还有“秋老虎”。24 节气准确反映地球围绕太阳公转而伴随着季节性规律,节气和纬度对昼夜长短的影响,以及各地区生活和生产用电规律,具有日周期性和年周期性。节气不仅对农业生产具有指导性,而且对电力系统的运行调度,特别在每年冷热两头诸节气的高峰调度控制,具有不可忽视的指导性。正因为如此,我们在将高峰负荷样本聚类时,注意形成节气工作日运行模式和节气节假日运行模式。

(d) 高峰负荷预测强调在外推功能方面下功夫,高峰负荷样本在负荷峰值、负荷高位陡升速率上接近历史记录,在每年冷热两头,容易出现破记录的情况。破记录事件的预测要求有较强的外推功能。有的记录被打破时,新老记录差距可能很大,例如东京电网负荷高位陡升速率历史记录的更新,曾经出现过翻一番的情况。这里气温与负荷需求存在严重的非线性关系,要想根据这种严重的非线性关系,较准确地预测历史记录翻番的情况,难度是相当大的。为此提出基于主成分分析 L - M 神经网络算法来提高高峰负荷预测精度。

## 2 L-M 神经网络算法的高峰负荷预测模型

按一年 24 节气、工作日与节假日对电网日运行样本聚类,每年每个节气(为期半月)建立一个工作日运行模式,每两个节气(为期一月)建立一个节假日运行模式,我们定义网络输入空间为:

$$X_i = (X_{1i}, X_{2i}, X_{3i}, X_{4i}, X_{5i}, X_{6i}, X_{7i}, X_{8i}) \quad (1)$$

式(1)中  $i = 1, 2, \dots, p$ ,  $p = 11$  或  $8$ ;  $X_{1i} = (l_{i1}, l_{i2}, \dots, l_{iq})$  为第  $i$  天  $q$  个整点的高峰负荷数据;  $X_{2i}$  为  $i$  日的日最高温度;  $X_{3i}$  为  $i$  日的日最低温度;  $X_{4i}$  为  $i$  日的天气状况;  $X_{5i}$  为  $i$  日的湿度;  $X_{6i}$  为  $i$  日的气压;  $X_{7i}$  为  $i$  日的峰值;  $X_{8i}$  为  $i$  日的日期类型。确定了网络输入空间后,还需要对式(1)中的各个分量进行归一化。

### 2.1 神经网络结构

神经网络的训练实质上是一个非线性目标函数的优化问题,网络的训练呈现出四个过程,即:输入

数据由输入层经中间隐含层向输出层的正向传播的过程;网络的预期输出与实际输出之差的误差信号,由输出层经中间隐含层向输入层,逐层修正连接权误差的逆向传递过程;数据正向传播与误差逆向传递的反复交替,进行网络“记忆训练”过程;网络趋向收敛及网络的全局误差趋向极小化的“学习收敛”的过程。

神经网络结构如图 1 所示。

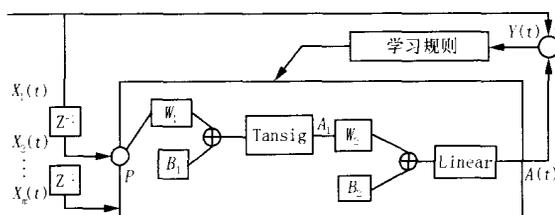


图 1 L-M 神经网络预测系统结构图

Fig. 1 Forecasting system architecture of L-M neural network

图 1 中的  $P = (X_1(t), X_2(t), \dots, X_m(t))$  为输入量, Tansig 为 S 型的正切激活函数和线性函数,  $W_1, W_2$  为权值,  $B_1, B_2$  为阈值,  $A_1 = (a_1, a_2, a_3)$  为隐层神经元输出,  $A(t)$  为输出层神经元的输出。在正向传播的过程中,输入信息从输入层经隐含层逐层计算传向输出层,每一层神经元的状态只能影响下一层神经元的状态。输入信息的正向传播:

隐含层中第  $i$  个神经元的输出为

$$a_{1i} = \text{Tansig} \left( \sum_{j=1}^m W_{1ij} X_j + B_{1i} \right), i = 1, 2, 3 \quad (2)$$

输出层神经元的输出为

$$A = \sum_{i=1}^3 W_{2i} a_{1i} + B_2 \quad (3)$$

定义误差函数为:

$$E(W, B, t) = \frac{1}{2} \sum_{i=1}^m [Y(t) - A(t)]^2 \quad (4)$$

通过神经网络,可以使下列式子成立

$$Y(t) = A(t) = f(X_1(t), \dots, X_m(t)) \quad (5)$$

网络设计的期望目标是使  $E(t) = Y(t) - A(t) = 0$ , 就可得网络输出  $A(t) = Y(t)$  的预测。用基于 L-M 数值优化的算法对网络的权值进行训练,信号沿原来的连接通路反转回来修改各层神经元的权值直至达到期望目标。以下简述 L-M 算法。

### 2.2 L-M 数值优化算法

通常 BP 算法以输出层的目标值与实际输出值之差的平方和作为目标函数,采用梯度下降法实质上是一种静态寻优算法,在修正权值  $W(k)$  时,只是按照时刻的负梯度的方向进行修正,没有考虑以前

时刻的梯度方向,常常使学习过程发生震荡,收敛速度缓慢,而 L - M 是动态数值优化算法,它结合了梯度下降法和 Gauss-Newton 法的优点,不仅利用了目标函数的一阶导数信息,还利用目标函数的二阶导数信息,在网络权值数目较小时收敛非常迅速,使学习时间明显缩短。以下对算法作简要说明,设  $W$  表示权值和阈值所组成的向量,向量的维数为  $n$ ,可按照下面的学习规则对权值修正<sup>[3]</sup>:

$$W(k+1) = W(k) + \Delta W(k) \quad (6)$$

$$\Delta W(k) = - [\nabla^2 E(k)]^{-1} \nabla E(k) \quad (7)$$

式(7)  $\nabla^2 E(k)$  表示误差函数  $E(k)$  的 Hessian 矩阵,  $\nabla E(k)$  表示梯度。对于 Gauss-Newton 法的学习法则有:

$$W = (J^T J)^{-1} J^T E \quad (8)$$

LM 算法是一种改进的 Gauss - Newton 法,它的形式为:

$$W = (J^T J + \mu I)^{-1} J^T E \quad (9)$$

其中

$$J = \begin{bmatrix} \frac{\partial e_1}{\partial w_1} & \dots & \frac{\partial e_1}{\partial w_n} \\ \dots & \ddots & \dots \\ \frac{\partial e_r}{\partial w_1} & \dots & \frac{\partial e_r}{\partial w_n} \end{bmatrix} \quad (10)$$

$J$  为误差对权值微分的 Jacobian 矩阵,  $E$  为误差向量,  $\mu > 0$  为非负标量,  $I$  是单位矩阵,理论上已经证明此方法收敛速度快,性能稳定<sup>[4]</sup>。当  $\mu$  很大时,公式(9)就接近于梯度下降法;当  $\mu$  很小时,公式(9)就变成 Gauss-Newton 法,在这种方法中,  $\mu$  也是自适应调整的。由于 LM 算法利用了近似的二阶导数信息,它比梯度下降法收敛快很多。

### 3 主成分分析

当网络输入参数很多时,L-M 算法需要很大的存储空间,为了减少网络输入不重要的参数,提高网络的运行效率,在使用 L-M 网络前对输入变量进行预处理,即主成分分析(principal component analysis),它是用降维的方法来处理高维数据,目的是用为数较少的不相关的新变量来反映原变量的绝大部分信息,这样可以使 L-M 算法迅速收敛。

设  $X = (x_1, x_2, \dots, x_p)^T$ ,求  $X$  的各主成分,等价于求它的协方差矩阵的各特征值及相应的正交单位特征向量  $\lambda_1, \lambda_2, \dots, \lambda_p$  及  $D = (d_1, d_2, \dots, d_p)$ 。

定义  $Y = (Y_1, Y_2, \dots, Y_p)^T$  为主成分向量,则

$$Y = D^T X \quad (11)$$

即主成分分析是按特征值由大到小所对应的正交单位特征向量为  $x_1, x_2, \dots, x_p$  的线性组合分别为  $x$  的第一、第二、直到第  $p$  个主成分,而各主成分的方差等于相应的特征值,即  $Var(Y_k) = \lambda_k$ 。

由上可知  $\sum_{i=1}^p \lambda_i$  描述了第  $k$  个主成分提取的信息占总信息的份额,我们称此为第  $k$  个主成分  $Y_k$  的贡献率<sup>[5]</sup>。第一主成分的贡献率最大,表明  $Y_1$  综合原始变量  $x_1, x_2, \dots, x_p$  所含信息的能力最强,而  $Y_1, Y_2, \dots, Y_p$  的综合能力依次减弱。前  $m$  个主成分  $Y_1, Y_2, \dots, Y_m$  综合提供  $x_1, x_2, \dots, x_p$  中信息的能力。

实际应用中,通常选取  $m < p$ ,使前  $m$  个主成分的累计贡献率达到较高的比例(如 80 %到 90 %)。这样用前  $m$  个主成分  $Y_1, Y_2, \dots, Y_m$  代替原始变量  $x_1, x_2, \dots, x_p$  不但使变量维数降低,而且也不致于明显损失原始变量中的信息。

### 4 数值算例分析

利用主成分分析 L-M 神经网络的方法对辽宁省 2002 年电网高峰负荷进行了预测。以小暑期间 7 月 2 日为例,预测结果如图 2 所示。图中高峰期区间为[18:30, 22:25],本文方法的平均绝对百分误差 MAPE 为 0.6623 %,最大绝对百分误差 2.1265 %,峰值误差 0.48717 %,网络学习训练次数 14 次;而普通 BP 方法平均绝对百分误差 MAPE 为 1.2594 %,最大绝对百分误差 2.3224 %,峰值误差 2.1401 %,网络学习训练次数 1000 次。

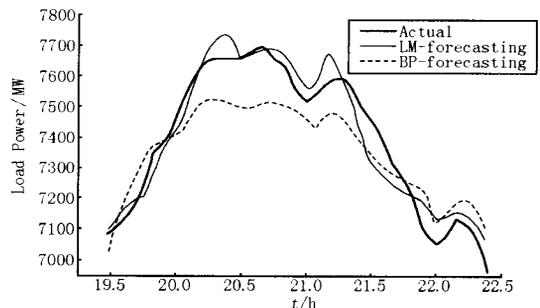


图 2 7 月 2 日本文预测与普通 BP 预测对比

Fig. 2 LM-forecasting data and BP-forecasting data on July 2, 2002

由此看出基于成分分析 L-M 神经网络的电网

高峰负荷预测精度及性能明显好于普通 BP 神经网络的预测方法。

以下将大寒期间的 12 个工作日高峰负荷预测误差及网络性能分析结果列入表 1。

表 1 2002 年大寒期间高峰负荷预测统计表

Tab. 1 Forecasted statistics of peak load during winter

日期	平均 误差/(%)	最大 误差/(%)	峰值 误差/(%)	训练 次数
<b>工作日</b>				
1 - 21	0.68	1.95	1.24	19
1 - 22	1.06	3.03	1.86	16
1 - 23	1.15	3.57	2.69	13
1 - 24	1.46	2.79	1.67	28
1 - 25	1.12	2.58	0.95	17
1 - 28	1.33	3.36	0.79	33
1 - 29	0.83	2.07	0.29	12
1 - 30	0.68	2.21	0.039	30
1 - 31	0.64	1.80	0.28	23
<b>节假日</b>				
1 - 20	1.03	3.58	1.31	37
1 - 26	1.07	3.32	1.57	5
1 - 27	1.55	3.61	2.09	19
平均	1.05	2.82	1.23	22

注:该表误差指相对百分比误差绝对值

## 5 结论

高峰负荷预测为电网调峰调频服务,从贯彻电网运行“安全、优质、经济”原则和防灾减灾的角度看,及时开展高峰负荷预测研究很有必要。使用主成分分析为 L-M 神经网络输入变量进行预处理,有助于高峰负荷预测的 L-M 神经网络算法迅速收敛,并且 L-M 神经网络预测模型对高峰负荷有较好的预测精度。

## 参考文献:

- [1] 刘长义,柳进,等(LIU Chang-yi, LIU Jin, et al). 提高电网攀峰响应能力的研究(Research on Enhancing Power System Responsive Ability for Climbing Steep Peak Load)[J]. 电力系统自动化(Automation of Electric Power Systems), 2002, 26(2): 34-37.
- [2] 从爽( CONG Shuang). 面向 MATLAB 工具箱的神经网络理论与应用(The Theory and Application of NN Based on Matlab)[M]. 合肥:中国科学技术大学出版社(Hefei: University of Science and Technology of China Press), 2003. 80-83.
- [3] 赵弘,周瑞祥,等(ZHAO Hong, ZHOU Rui-xiang, et al). 基于 Levenberg-Marquardt 算法的神经网络监督控制(Neural Network Supervised Control Based on Levenberg-Marquardt Algorithm)[J]. 西安交通大学报(Journal of Xi'an Jiaotong University), 2002, 36(5): 523-527.
- [4] Efe M O, Kaynak O. A Novel Optimization Procedure for Training of Fuzzy Inference Systems by Combining Variable Structure Systems Technique and Levenberg-Marquardt Algorithm[J]. Fuzzy Sets and Systems, 2001, 122: 153-165.
- [5] 范金城,梅长林(FAN Jin-cheng, MEI Chang-lin). 数据分析(Data Analysis)[M]. 北京:科学出版社(Beijing: Science Press), 2002.

收稿日期: 2003-10-20; 修回日期: 2003-12-16

作者简介:

柳进(1958-)女,副教授,在职攻读博士学位,研究方向为模式识别与人工智能在电力系统的应用;

E-mail: Liu jin @hit.edu.cn

唐降龙(1960-)男,教授,博士生导师,研究方向为模式识别与人工智能。

## Peak load forecasting based on neural network with principal component analysis

LIU Jin, TANG Xiang-long

(Harbin Institute of Technology, Harbin 150001, China)

**Abstract:** This paper dissertates the necessity and peculiarities of the peak load forecasting. According to the records of workday and holidays, peak load samples are clustered. The principal component analysis approach can reduce the vectorial dimension in the inputting space and keep the useful information of input vector. Then using the predicting model of L-M optimizing algorithm with multilevel neural network simulates Liaoning peak load forecasting and the predicting precision is satisfactory.

**Key words:** peak load forecasting; operating pattern; principal component analysis; neural network