

神经网络预测中长期电力负荷对比研究

师兵兵, 段哲民, 陆正俊

(西北工业大学电子信息学院, 陕西 西安 710072)

摘要: 为避免传统方法预测中长期电力负荷建模的复杂性, 根据电力负荷历史数据, 研究了基于LM算法的BP网络、RBF网络在中长期电力负荷预测中的应用, 通过神经网络对训练样本的学习, 自动提取影响中长期电力负荷的诸多因素。从训练速度、预测误差等方面分析对比了两种神经网络预测能力, 仿真和实例数据表明了两种神经网络在中长期电力负荷预测方面的可行性和良好效果。

关键词: 电力负荷; 神经网络; 反向传播; 径向基函数; 预测

Research and comparison of neural networks for forecasting mid-long term power load

SHI Bing-bing, DUAN Zhe-min, LU Zheng-jun

(Department of Electronic and Information, Northwestern Polytechnical University, Xi'an 710072, China)

Abstract: In order to avoid the complex forecasting model of mid-long term power load by traditional methods, the research of mid-long term power load based on BP network and RBF network is done according to the past power load data. Two networks can obtain lots of factors from training samples automatically which influence power load. The ability of two networks for forecasting is compared with the training speed and forecasting errors. Two networks have a good performance in forecasting the power load verified by the simulation results and the measured values.

Key words: power load; neural network; BP; RBF; forecasting

中图分类号: TM715; TP183

文献标识码: A

文章编号: 1003-4897(2007)23-0043-03

0 引言

电力负荷预测是电力企业高效调度、正常生产的重要前提, 涉及社会生产、人们生活的各个方面。预测方法有趋势外推法^[1]、非线性偏最小二乘回归模型^[2]、灰色模型群建模^[3]及基于相关分析的综合预测模型^[4]等, 通过建立预测对象的精确数学模型可取得比较符合实际的预测结果。应用神经网络进行预测, 不需要建立预测对象的精确数学模型, 样本数据本身就包含诸多影响电力负荷量大小的因素, 因此, 基于LM算法的BP网络、RBF网络通过对样本数据的训练, 可将影响电力负荷的因素诸如天气等自动融合进去, 不必精确建立预测对象数学模型即可得到比较满意的预测结果。

1 BP网络的LM(Levenberg-Marquardt)算法

BP(Back Propagation)神经网络是由信号的正向传播和误差的反向传播组成, 通过训练不断调整神经元连接权值和阈值, 直至达到设定训练目标为

止, 其模型结构如图1所示。BP网络是一种全局逼近网络, 理论上可以逼近任一连续函数。BP网络存在训练速度慢、时间长、易陷入局部极小等缺点。

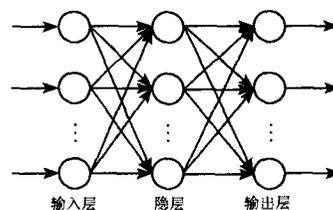


图1 BP网络模型

Fig.1 Model of BP network

LM算法^[5,6]是一种类似于牛顿法的快速算法, 是牛顿法和梯度下降法的一种折衷, 可以极大地改善BP网络的固有缺陷和不足, 可以不用计算Hessian矩阵而具有牛顿法的速度和精度, 由于BP网络其表现函数为均方误差, 具有平方和的形式,

可表示为 $F(x) = \sum_{i=1}^N v_i^2(x) = v^T(x)v(x)$, 其中

$v(x)$ 为网络误差向量。根据牛顿法 $x(k+1) = x(k) - A^{-1}(k)g(k)$, 其中 $x(k)$ 为第 k 次迭代各层间的连接权值向量或阈值向量, $A(k) = \nabla^2 F(x)|_{x=x(k)} \approx 2J^T J$, $g(k) = \nabla F(x)|_{x=x(k)} = 2J^T v$, 可得高斯-牛顿公式 $x(k+1) = x(k) - [J^T J]^{-1} J^T v$, 考虑 $J^T J$ 未必可逆, 令 $G = J^T J + \mu I$, 合适选取 μ , 可证得该矩阵正定可逆^[5]。于是可得 LM 算法迭代公式 $x(k+1) = x(k) - [J^T J + \mu I]^{-1} J^T v$, 亦即 $\Delta x(k) = -[J^T J + \mu I]^{-1} J^T v$, 其中 $J^T J + \mu I$ 为近似 Hessian 矩阵,

$$J = \begin{bmatrix} \frac{\partial v_1(x)}{\partial x_1} & \frac{\partial v_1(x)}{\partial x_2} & \dots & \frac{\partial v_1(x)}{\partial x_n} \\ \frac{\partial v_2(x)}{\partial x_1} & \frac{\partial v_2(x)}{\partial x_2} & \dots & \frac{\partial v_2(x)}{\partial x_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial v_N(x)}{\partial x_1} & \frac{\partial v_N(x)}{\partial x_2} & \dots & \frac{\partial v_N(x)}{\partial x_n} \end{bmatrix}$$

当 μ 为 0 时, 上式变为牛顿法。当 μ 较大时, 上式近似于步长较小的梯度下降法。

LM 算法迭代过程^[5]如下:

(1) 计算网络误差向量 $v(x)$ 及 $F(x)$ 。

(2) 通过计算 J 得到 $\Delta x(k)$ 。

(3) 用 $x(k) + \Delta x(k)$ 迭代计算, 若误差比上次大, 则用 μ 除以 $\theta(0 < \theta < 1)$, 转至(2); 反之, 则用 μ 乘以 $\theta(0 < \theta < 1)$, 转至(1), 直至达到设定目标为止。

2 RBF 径向基函数神经网络原理

RBF(Radial Basis Function)径向基函数神经网络是一种具有单隐层的三层前馈网络, 是一种局部逼近网络, 而且能以任意精度逼近任意连续函数, 其模型结构如图 2 所示。

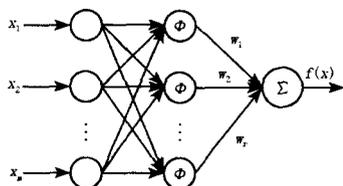


图 2 RBF 网络模型

Fig.2 Model of RBF network

一般来说, 对同一任务, 径向基函数神经网络所需神经元数目多于 BP 网络, 但其速度更快。径向基函数为 $radbas(n) = e^{-n^2}$, 网络的输出^[6]为

$y = radbas(\|W - X\| \cdot b)$, 其中 X 、 W 、 b 分别为网络输入向量、权值向量、阈值。

3 负荷量数据处理

应用神经网络进行中长期电力负荷预测, 可以充分发挥神经网络的非线性映射优势, 比较全面地综合各个影响电力负荷大小的因素, 使预测更接近实际情况。通过某地区 1999~2003 年四季实际电力负荷数据^[7], 以 1999~2002 年四季负荷为样本来训练, 预测 2003 年四季电力负荷并验证。

为了减小奇异样本对神经网络性能的影响, 对样本进行归一化处理, 使其范围在区间 $[0, 1]$ 之间。

$$y = \frac{x - x_{\min}}{x_{\max} - x_{\min}}$$

其中 y 为某项 x 归一化输出, x_{\min} 取所有 x 中最小值, x_{\max} 可取所有 x 中最大值, 也可取某一比所有 x 更大的数, 考虑当地电力负荷量增长态势以及应用神经网络预测而非插值, 故取后者。需要说明的是, 训练样本归一化处理有多种方式。1999~2002 年四季负荷归一化数据如表 1 所示。

表 1 负荷归一化值

Tab.1 Return results of the load

季度	1	2	3	4
1999 年	0.000	0.112	0.066	0.126
2000 年	0.032	0.186	0.194	0.256
2001 年	0.138	0.32	0.338	0.4
2002 年	0.298	0.542	0.57	0.678

4 预测对比分析

基于 LM 算法的 BP 网络隐单元数根据如下经验公式来确定,

$n = \sqrt{n_1 + n_2} + a$, 其中 n 、 n_1 、 n_2 分别为隐单元数、输入单元数、输出单元数, a 为 $[0, 10]$ 之间的整数。

基于 LM 算法的 BP 网络经过反复训练和对比, 最终确定最佳隐单元数为 6, 训练误差曲线如图 3 所示。

RBF 网络的分布密度 SPREAD 对训练结果有着非常重要的影响, 分布密度 SPREAD 越小, 对函数逼近越精确, 但逼近过程不光滑, SPREAD 越大, 逼近过程变得越光滑, 但逼近函数精确度要差。经过仔细对比分析, 综合考虑最终取 0.8, RBF 网络训练误差曲线如图 4 所示。

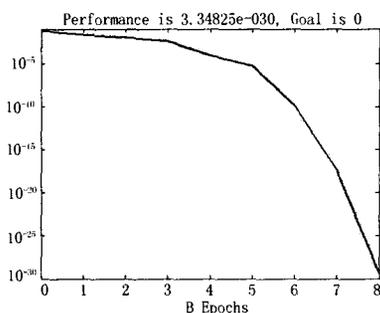


图3 BP网络LM算法训练误差曲线

Fig.3 LM training error curve of BP network

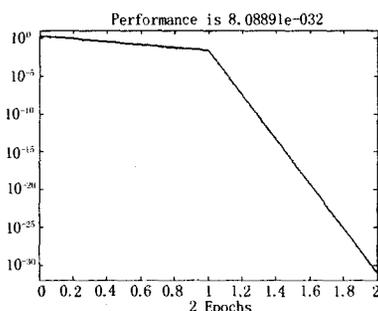


图4 RBF网络训练误差曲线

Fig.4 Training error curve of RBF network

将预测结果反归一化处理, BP网络、RBF网络预测结果与实际负荷量对比如图5所示。

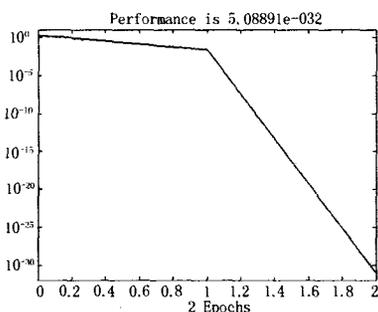


图5 预测结果

Fig.5 Results of forecasting

基于LM算法的BP网络和RBF网络预测相对误差见表2, 灰色模型GM(1,1)、灰色季节变动指数模型GSVI(1,1)相对误差为文献[7]预测所得。

通过上述曲线和数据对比, 可看出:

(1) LM算法可明显改变BP网络训练速度, 接近RBF网络训练速度。

(2) BP网络预测最大、最小相对误差分别为5.58%、-0.68%, RBF网络预测最大、最小相对误差分别为9.23%、-1.21%, 将两种网络用作预测其相

对误差并不大, 预测结果还与影响电力负荷的各因素的稳定性和相对重复性有关。

(3) 与其它预测方法相比, 基于LM算法的BP网络和RBF网络整体预测效果要好于GM(1,1)模型, 基于LM算法的BP网络预测相对误差与灰色季节变动指数模型GSVI(1,1)模型接近, 有很好的预测能力。

表2 预测相对误差

Tab.2 Error of prediction with measured value

2003年各季度	1	2	3	4
负荷实际值/MWh	58.8	69.5	76.9	80.2
BP模型预测值/MWh	55.520	71.595	77.425	81.520
BP模型相对误差/(%)	5.58	-3.01	-0.68	-1.65
RBF模型预测值/MWh	53.375	70.340	71.625	83.890
RBF模型相对误差/(%)	9.23	-1.21	6.86	-4.60
GM(1,1)模型相对误差/(%)	-10.00	2.66	7.84	7.42
GSVI(1,1)相对误差/(%)	2.72	-0.79	5.50	2.58

5 结束语

预测对比表明, 基于LM算法的BP网络、RBF网络训练速度快, 不必精确建立电力负荷数学模型即可有效预测中长期电力负荷, 所得结果可满足电力企业调度的需要, 为中长期电力负荷预测提供了一个有效方法和更多选择。

参考文献

- [1] 李栓, 刘莉, 刘阳. 趋势外推法在电力负荷预测中的应用[J]. 沈阳工程学院学报(自然科学版), 2005, 1(2, 3): 64-65.
LI Shuan, LIU Li, LIU Yang. Application of Trends Extrapolation on the Power Load Forecast[J]. Journal of Shenyang Institute of Engineering(Natural Science), 2005, 1(2, 3): 64-65.
- [2] 蔡金錠, 王慧. 非线性偏最小二乘回归在电力负荷预测中的应用[J]. 电工电能新技术, 2006, 25(2): 15-17.
CAI Jin-ding, WANG Hui. Application of Non-linear Partial Least Square Regression in Electricity Load Prediction[J]. Advanced Technology of Electrical Engineering and Energy, 2006, 25(2): 15-17.
- [3] 牛东晓, 张彤彤, 陈立荣, 等. 基于关联分析的多因素电力负荷预测灰色模型群研究[J]. 华北电力大学学报, 2006, 33(3): 90-92.
NIU Dong-xiao, ZHANG Tong-tong, CHEN Li-rong, et al. Grey Load Forecasting Models Based on Relational Analysis of Multi-factor[J]. Journal of North China Electric Power University, 2006, 33(3): 90-92.
- [4] 虞瑄, 程浩忠, 王旭, 等. 基于相关分析的中长期电力负荷综合预测方法[J]. 继电器, 2005, 33(15): 49-52.

(下转第59页 continued on page 59)

波时的相对误差高达-2.8814%和-2.4330%;采用本算法相位估计结果明显优于采用文献6中方法的估计结果,只有在2次谐波时误差为-2.4609%,即相角的测量误差为 0.98° ,而文献[6]中相位估计结果的相对误差则普遍较大,尤其2,3次谐波时的相对误差分别高达15.0695%和7.2534%,因此本算法优于文献[6]中加Hanning窗的插值FFT算法,更适合于电网谐波分析。

4 结语

本文先通过带通滤波器分离出基波和各次谐波,这样可有效地降低高斯白噪声对电网参数测量精度的影响,且由于已分离出基波和各次谐波,因此在对分离出的信号进行短时傅里叶变换时不存在频谱泄漏问题,并采用插值算法对测得的频率、幅值和相位进行校正,消除了短时傅里叶变换中的栅栏效应。该算法可准确检测出基波和各次谐波的频率、幅值和相位,可以分析高达63次谐波,适用于电力系统谐波的实时检测。

参考文献

- [1] 周厚奎,张昱,金心宇.基于傅里叶和小波变换的电网谐波分析[J].电力系统及其自动化学报,2005,29(6):63-66,103.
ZHOU Hou-kui,ZHANG Yu,JIN Xin-yu. Power Harmonic Analysis Based on Fourier and Wavelet Transform[J]. Proceedings of the CSU-EPSSA, 2005,29(6):63-66,103.
- [2] 胡广书.现代信号处理教程[M].北京:清华大学出版

社,2004.

HU Guang-shu. Modern Signal Processing[M]. Beijing: Tsinghua University Press,2004.

- [3] Shensa M J.The Discrete Wavelet Transform: Wedding the Trous and Mallat Algorithms[J]. IEEE Trans on Signal Proc,1992,40(10):2464-2482.
- [4] 谢明.离散频谱分析的一种新校正方法[J].重庆大学学报,1995,(2):52-59.
XIE Ming. New Rectifying Technique of Spectrum Analysis[J]. Journal of Chongqing University,1995,(2):52-59.
- [5] 柴旭峰,文习山,关根志,等.一种高精度的电力系统谐波分析算法[J].中国电机工程学报,2003,27(9):60-70.
CHAI Xu-zheng, WEN Xi-shan,GUAN Gen-zhi,et al. An Algrithm with High Accuracy for Analysis of Power System Harmonic[J]. Proceedings of the CSEE,2003,27(9):60-70.
- [6] 祁才君,陈隆道,王小海.应用插值FFT算法精确估计电网谐波参数[J].浙江大学学报,2003,(1):114-118.
QI Cai-jun, CHEN Long-dao, WANG Xiao-hai. High-accuracy Estimation of Electrical Harmonic Parameters by Using the Interpolated FFT Algorithm[J]. Journal of Zhejiang University (Engineering Science), 2003,(1):114-118.

收稿日期:2007-04-28; 修回日期:2007-07-03

作者简介:

刘俊(1983-),男,硕士研究生,主要研究方向为电力系统谐波分析。E-mail:ljshoot@tom.com

(上接第45页 continued from page 45)

- YU Xuan, CHENG Hao-zhong, WANG Xu, et al.A Combined Power System Mid-long Term Load Forecast Method Based on the Correlation Analysis[J]. Relay, 2005, 33(15): 49-52.
- [5] Hagan M T, Demuth H B, Beale M H. 戴葵,等译.神经网络设计[M].北京:机械工业出版社,2002.
Hagan M T, Demuth H B, Beale M H. Neural Network Design[M]. DAI Kui, et al Trans. Beijing: China Machine Press, 2002.
- [6] 周开利,康耀红.神经网络模型及其MATLAB仿真程序设计[M].北京:清华大学出版社,2005.
ZHOU Kai-li, KANG Yao-hong. Model of Neural Network and Simulation Program Design by Matlab[M]. Beijing: Tsinghua University Press, 2005.
- [7] 李松,刘波.灰色季节变动指数模型GSVI(1,1)在农

村用电量预测中的应用[J].中国电力,2006,39(6):15-18.

LI Song, LIU Bo. Application of Gray Seasonal Variation Index Model GSVI(1,1) in Country Electricity Demand Forecasting[J].Electric Power, 2006, 39(6):15-18.

收稿日期:2007-05-21; 修回日期:2007-06-25

作者简介:

师兵兵(1978-),男,硕士研究生,研究方向为智能信息处理与检测技术;E-mail: vitamin911@hotmail.com

段哲民(1953-),男,教授,博导,主要从事电工理论与新技术、电路与系统学科研究和教学工作。

陆正俊(1980-),男,硕士研究生,研究方向为数据采集与信号处理。