

基于混沌神经网络理论的小电网 短期电力负荷预测

李 广¹, 邹德忠², 谈顺涛¹

(1. 武汉大学 电气工程学院, 湖北 武汉 430072; 2. 葛洲坝实业公司, 湖北 武汉 430033)

摘要: 通过对小电网负荷数据的特点分析, 将时间序列处理、混沌理论和神经网络理论相结合提出了一种基于混沌神经网络理论的电力负荷预测模型。利用 Matlab 对实际数据进行了仿真计算。通过实例计算, 并和不用相空间重构的神经网络的负荷预测算法的各种误差指标的分析比较说明, 利用相空间重构对历史数据序列进行拆分或重构可以提高负荷预测的精度。

关键词: 短期负荷预测; 非线性理论; 混沌理论; 相空间重构; 神经网络; 时间序列

中图分类号: TM 715; TP 18

文献标识码: A

文章编号: 1006-6047(2006)02-0050-03

目前, 由于各地区电网的配网自动化工作展开, 小地区电网的负荷预测越来越受到关注。在此小地区电网主要是指县级电网, 和大电网相比较, 小地区电网电力负荷的特点是: 容量较小, 一般只有几十到一二百兆伏安; 突变较大; 峰谷相对变化较大, 其最高负荷往往会接近最低负荷的 2 倍。而传统的电力负荷预测模型^[1-2]多是将短期电力负荷作为随机过程。本文根据小地区电网的负荷特点, 将时间序列处理、混沌理论和神经网络理论相结合提出了一种基于混沌神经网络理论的电力负荷预测模型。

1 电力负荷短期预测方法

基于混沌神经网络的电力负荷短期预测模型主要是将经过时间序列处理的负荷数据, 利用相空间重构理论对其进行重构和拆分, 拆分为训练向量和预测向量, 并将其送入神经网络进行训练和预测得出初步预测结果, 最后进行时间序列的反运算, 得出最终预测结果。下面介绍该方法的具体步骤。

a. 对原始负荷序列的时间序列处理。 时间处理^[3-4]包括平滑、差分、去基值和比例放大 4 种处理方式。为了叙述方便, 将经过时间序列处理之后的数据序列继续用 $\{x_i\}$ 表示。

b. 计算嵌入维 m 和延迟 τ 。 在本文所提负荷预测模型中采用了去偏复自相关法^[5], 对于经过时间序列处理后的序列 $\{x_i\}$, 计算其去偏复自相关函数:

$$C_{xx}^m(\tau) = R_{xx}^m(j\tau) - (m-1)(\bar{x})^2$$

$$R_{xx}^m(j\tau) = \frac{1}{N} \sum_{j=1}^{m-1} \sum_{i=1}^{N-j\tau} x_i x_{i+j\tau} \quad (1)$$

式中 $\bar{x}$ 为序列的均值。

由于去偏复自相关去除了时间序列的均值, 因此序列 $\{x_n\}$ 在 m 维相空间的复自相关法取 $C_{xx}^m(\tau)$

的第 1 个 0 点所对应的时间作为时间延迟 τ 。

c. 相空间重构^[6]和数据拆分。 首先将序列 $\{x_n\}$ 按照嵌入维数 $m+1$ 和延迟 τ 进行重构得到训练向量集合, 如下所示:

$$[X_1, X_2, \dots, X_{n-m \times \tau}] = \begin{bmatrix} x_1 & x_2 & \dots & x_{n-m \times \tau} \\ x_{1+\tau} & x_{2+\tau} & \dots & x_{n-(m+1) \times \tau} \\ \vdots & \vdots & \dots & \vdots \\ x_{1+(m-1) \times \tau} & x_{2+(m-1) \times \tau} & \dots & x_{n-\tau} \\ x_{1+m \times \tau} & x_{2+m \times \tau} & \dots & x_n \end{bmatrix} \quad (2)$$

再从原序列 $\{x_n\}$ 的第 $n+1-\tau$ 个数, 即 $x_{n+1-\tau}$, 开始每隔一个 τ 取一个数, 取至第 $n+1-m \times \tau$ 个数, 即 $x_{n+1-m \times \tau}$, 从而形成预测向量 $(x_{n+1-m \times \tau}, x_{n+1-(m+1) \times \tau}, \dots, x_{n+1-\tau})^T$ 。

d. 神经网络训练及预测。 由于 BP 网络对非线性映射的逼近较为稳定, 因此, 在本文提出的方法中所采用的 BP 网络, 根据文献^[2]中所提到的 Kolmogorov 的连续函数表示定理及其相关定理, 任何一个高度的非线性映射 Φ 可以由一个 3 层神经网络精确表示, 因此采用 3 层网络结构。

输入层: 对应于序列重构后的嵌入维 m , 设 m 个输入节点。

第 1 隐藏层: 设 $2m$ 个节点, 取激活函数为正切 s 型函数。

第 2 隐藏层: 设 m 个节点, 和第 1 隐藏层一样取激活函数为正切 s 型函数。

正切 s 型函数的表达式如下:

$$y = \frac{2}{1 + e^{-2x}} - 1 \quad (3)$$

输出层: 由于本文试验中采用的是步预测, 输出节点数为 1, 其激活函数为线性函数。

线性函数表达式如下:

$$y = x \quad (4)$$

将 c 中所拆分的训练向量集合的向量依次送入

BP 网络,其中每个向量的前 m 个数据输入到输入层,作为训练数据,而第 $m+1$ 个数据作为理想输出,同每次训练所得的结果相比较,以调整神经网络的权重,当训练完成以后输入预测向量得出预测结果。

2 算例分析

根据本算法在 Matlab 环境下,利用某市电网 2004 年 5 月 1 号 0:00~2004 年 8 月 4 号 19:00 共 2 300 个点的数据进行了仿真预测计算,其中最后 50 个点作为未知点进行预测试验,效果理想。为了进行比较,本文还利用没有经过相空间重构的神经网络预测^[7]的方法对试验数据进行预测计算,两者在最优参数组合下的计算结果如表 1 所示。

表 1 两种方法的预测结果
Tab.1 Forecast result comparison

原始序列	混沌 BP	BP	原始序列	混沌 BP	BP
46.780	46.801	46.616	42.900	43.145	42.581
46.520	47.923	47.678	42.580	43.592	42.969
47.620	47.402	47.517	42.910	40.990	41.342
47.550	47.131	47.585	41.130	43.400	42.616
47.507	46.765	46.882	42.520	41.569	40.710
46.780	48.451	47.293	40.700	39.809	39.323
47.060	50.596	48.922	39.350	37.601	35.653
48.830	48.870	47.003	35.760	34.498	32.601
47.020	47.594	45.469	32.920	31.912	31.049
45.590	44.420	41.944	31.380	32.925	32.808
42.290	39.012	37.364	32.930	33.454	32.289
37.810	36.360	37.077	32.410	31.985	32.704
37.390	37.204	36.538	32.780	32.366	34.728
36.660	35.653	36.058	34.610	36.014	36.350
36.180	35.530	37.991	36.050	35.343	38.369
37.990	38.000	40.707	38.020	38.359	41.919
40.610	39.780	42.126	41.520	44.725	45.874
41.870	40.991	41.997	45.580	41.673	42.536
41.730	45.297	45.339	42.410	41.688	40.472
44.950	49.002	48.962	40.390	40.119	38.449
48.690	45.204	44.319	38.490	39.229	39.052
44.060	43.286	41.299	39.040	39.511	39.388
41.200	43.099	42.867	39.400	39.348	38.868
42.780	42.253	42.042	38.920	39.696	39.392
42.060	43.491	42.969	39.380	37.888	37.925

从表 1 中可以看到混沌神经网络预测明显要比没有经过相空间重构后的神经网络预测更加接近负荷的历史数据。从相对误差上看,混沌神经网络预测计算的相对误差平均值为 0.029 9,没有经过相空间重构的神经网络预测的方法所预测计算的相对误差平均值为 0.041 1,前者比后者下降了 0.0112。表 2 为相对误差分布。

从表中可看出利用本文所提出的混沌神经网络算法所预测的 50 个点的数据中,其误差分布在 5 % 以下的有 42 个点,占总数的 84 %,而且没有误差高于 10 % 的点。而在相同历史数据和预测点数的情况下,没有经过相空间重构的神经网络预测方法所预测的 50 个点的数据中,其误差分布在 5 % 以下的

表 2 相对误差分布
Tab.2 Relative error distribution

区段	混沌 BP	BP	区段	混沌 BP	BP
0~1%	10	8	6%~7%	0	3
1%~2%	13	9	7%~8%	4	2
2%~3%	7	3	8%~9%	2	4
3%~4%	7	8	9%~10%	1	1
4%~5%	5	5	>10%	0	3
5%~6%	1	4			

只有 33 个点,占总数的 66 %,有 3 个误差高于 10 % 的点,占总数的 6 %。在误差较低的区段内,它所分布的点数明显比不用相空间重构的神经网络作出的预测所分布的点数要多。

从关联度上看^[8],混沌神经网络算法所预测的数据与原始数据的关联度为 $rel_1=0.706\ 8$;而不用相空间重构的神经网络的预测算法所预测的数据与原始数据的关联度为 $rel_2=0.638\ 7$ 。 $rel_1>rel_2$,因此,前者与原始数据的拟和程度更优,准确度更高。

3 结语

本文提出了将时间序列处理、混沌序列的相空间重构以及神经网络训练三者相结合的短期电力负荷预测算法;并在此基础上,利用 Matlab 对实际数据进行了仿真计算。通过实例计算,并和不用相空间重构的神经网络的负荷预测算法的各种误差指标的分析比较说明,利用相空间重构对历史数据序列进行拆分或重构可以提高负荷预测的精度。

参考文献:

[1] 梁志珊,王丽敏,付大鹏. 应用混沌理论的电力系统短期负荷预测[J]. 控制与决策,1998,13(1):87-90.
LIANG Zhi-shan,WANG Li-min,FU Da-peng. Short term load forecasting using chaos[J]. **Theory Control and Decision**,1998,13(1):87-90.

[2] 杨正瓴,林孔元. 短期负荷预测相空间重构法参数优选的数值测试与分析[J]. 电力系统自动化,2003,27(16): 40-44.
YAN Zheng-ling,LIN Kong-yuan. Improving precision of short term load forecasting by numerical testing in local linearization method of phase space reconstruction[J]. **Automation of Electric Power Systems**,2003,27(16): 40-44.

[3] 张树京,齐立心. 时间序列分析简明教程[M]. 北京:清华大学出版社,2003.

[4] 何书元. 应用时间序列分析[M]. 北京:北京大学出版社,2003.

[5] CHOI Jae-gyun,PARK Jong-keun. A daily peak load forecasting system using a chaotic time series[C]// **ISAP'96**. Japan:[s.n.],1996:283-287.

[6] MORI H,VRANO S. Short-term load forecasting with chaos time series analysis[C]// **ISAP'96**. Japan:[s.n.], 1996:133-137.

[7] 温权,张勇传,程时杰. 负荷预报的混沌时间序列分析方

法[J]. 电网技术,2001,25(10):13-16.

WEN Quan,ZHAN Yong-chuan,CHENG Shi-jie. Chaotic time series analysis to load prediction[J]. **Power System Technology**,2001,25(10):13-16.

[8] 孙小军. 试验数据间的关联度分析[J]. 红外技术,1994,16(3):39-40.

SUN Xiao-jun. Analysis the relation grade among testing data[J]. **Technology of Infrared**,1994,16(3):39-40.

[9] 焦李成. 神经网络系统理论[M]. 西安:西安电子科技大学出版社,1990.

(责任编辑:李 玲)

作者简介:

李 广(1978-),男,湖北宜昌人,硕士,主要从事电力系统运行与控制、电力负荷预报和大型发电机方面的研究(E-mail: guang_li@126.com);

邹德忠(1968-),男,湖北宜昌人,主要从事大型发电机设备管理工作;

谈顺涛(1947-),男,上海人,教授,主要研究方向为电力系统稳定控制、自动控制理论在电力系统中的应用等。

Short-term load forecast for small power net based on chaos-artificial neural network theory

LI Guang¹, ZOU De-zhong², TAN Shun-tao¹

(1. School of Electrical Engineering, Wuhan University, Wuhan 430072, China;

2. Gezhou Dam Industrial Company, Wuhan 430033, China)

Abstract: According to the summarized features of load data in small power net, a chaos-artificial neural network theory based on load forecast model is presented, which combines time series processing, chaos theory and neural network theory together. Actual data are used for forecast simulation with Matlab. The forecast error indices of neural network with and without phase space reconstruction are compared through computation. Results prove that using phase space reconstruction to split and reconstruct the historical data can improve the precision of load forecast.

Key words: short-term load forecast; nonlinear theory; chaos theory; phase space reconstruction; artificial neural network; time series