

doi: 10.3969/j.issn.1006-1576.2011.11.012

基于混沌理论和 BP 神经网络的某基地电力短期负荷预测

宋振宇¹, 谭勛^{2,3}, 刘宇², 邵阳⁴

(1. 海军航空工程学院科研部, 山东 烟台 264001; 2. 海军航空工程学院研究生管理大队, 山东 烟台 264001;
3. 中国人民解放军 92330 部队, 山东 青岛 266102; 4. 南瑞集团配电与用电研究所, 南京 211800)

摘要: 为了合理安排并优先保证军事基地中的电力调度问题, 提出一种基于混沌时间序列和 BP 神经网络相结合的电力短期负荷预测方法。根据混沌理论及神经网络方法, 先基于延迟坐标相空间重构技术, 再应用互信息法和饱和关联维数法, 选择延迟时间 τ 和嵌入维数 m , 然后用 BP 神经网络来实现预测, 并通过对海军某基地的电网的时间负荷序列进行实测仿真。仿真结果表明: 相对误差均在 5% 以内, 且有 33.3% 的误差在 1% 以内, 证明该预测方法具有较高的预测精度和应用价值。

关键词: 混沌时间序列; BP 神经网络; 短期负荷预测

中图分类号: TJ06 **文献标志码:** A

Short-Term Load Forecasting of Navy Certain Base Based on Chaotic Time Series and Artificial Neural Networks

Song Zhenyu¹, Tan Xu^{2,3}, Liu Yu², Shao Yang⁴

(1. Dept. of Scientific & Research, Naval Aeronautical & Astronautical University, Yantai 264001, China;
2. Administrant Brigade of Postgraduate, Naval Aeronautical & Astronautical University, Yantai 264001, China;
3. No. 92330 Unit of PLA, Qingdao 266102, China;
4. Power Distribution & Utilization Research Institute, NanRui Group, Nanjing 211800, China)

Abstract: In order to rationally arrange and give priority to ensuring the power dispatching problem of a military base, a method of short-term load forecasting based on chaotic time series and artificial neural networks is presented. According to chaos theory and neural networks method, it is based on the delay coordinates phase space reconstruction first, choose time delay ' τ ' and embedding dimension ' m ' by using the method of mutual information and saturation correlation dimension after, then use the BP neural networks prediction, carry out an experimental simulation about grid in the period of load sequence on a base finally. The simulation results show that the relative errors is within 5%, and 33.3% of the error is less than 1%, proved that the prediction method has higher forecasting precision and application value.

Keywords: chaotic time series; short-term load forecasting; artificial neural network

0 引言

随着现代化军队建设的发展, 军事基地规模呈现出越来越庞大的趋势, 营区及各项武器装备耗电量加大, 基地的用电负荷在逐步增长。一旦发生紧急情况或者在战时, 安排合理的电力调度使得军事基地用电能够得到优先保证, 这对国防安全具有重大意义。在电力系统中, 日负荷预测和周负荷预测为短期负荷预测^[1], 分别用来安排日调度计划和周调度计划, 包括确定机组的起停、水火电的协调、联络线交换功率、和设备检修等。在长期的实践中, 人们开发了许多短期负荷预测的方法, 主要包括: 时间序列法^[2]、人工神经网络法^[3-4]、模糊预测法^[5]、灰色模型法、小波分析法。由于电力系统是一个非线性大系统, 并表现出一定的混沌行为, 因此, 负荷表现出复杂而难以精确预测的特征, 导致以上的

预测方法都有一定的局限性。

随着混沌科学的发展, 预测可以不必事先建立主观数学模型, 而是根据序列本身计算找出其规律, 然后进行预测, 得出满意的预测结果。因此, 笔者提出一种基于混沌时间序列和 BP 神经网络相结合的电力短期负荷预测方法。

1 相空间重构

混沌时间序列预测的基础是状态空间的重构理论, 即把具有混沌特性的时间序列重建为一种低阶非线性动力学系统。通过相空间重构, 可以找出隐藏在混沌吸引子中的演化规律, 使现有的数据纳入某种可描述的框架之下, 从而为时间序列的研究提供了一种崭新的方法和思路。对于时间序列 $\{X_i, i=1, 2, 3, \dots, n\}$, n 为序列的长度, 荷兰数学家 Bogdanov-Takens 提出的嵌入定理, 通过相空间重

收稿日期: 2011-07-16; 修回日期: 2011-08-26

作者简介: 宋振宇(1961—), 男, 山西人, 硕士, 副教授, 硕士生导师, 从事军事装备综合保障研究。

构法, 可得到新的数据空间:

$$X_i = (x_i, x_{i+\tau}, \dots, x_{i+(m-1)\tau}) \quad (1)$$

式中: m 为混沌时间序列的嵌入维数; τ 为延迟坐标时间。

1.1 延迟时间 τ 的求取

嵌入理论中对延迟时间 τ 未作限制, 但实际应用中, τ 不宜过大也不宜过小。 τ 过大, 系统中一个时刻的状态和其后的状态在因果关系上变得毫不相关, 使轨道上相邻点投影到不相关的方向上, 这样即使简单的轨道也看起来极为复杂, 同时也将减少使用的有效数据点数, 称此现象为不相关 (irrelevance)。 τ 过小, 将会使重构的动力系统相轨道由于相关性较强, 挤压在对角线方向上, 从而不能展示系统的动力特征, 称之为冗余重合现象 (redundance)。 目前, 延迟时间的选取方法主要有自相关法, 复自相关法和互信息法。 由于互信息法能克服自相关函数法只反映变量间线性相关程度的局限性, 还能度量变量间的非线性的广义相关关系。 具体的方法是:

对于时间序列 $\{X_i, i = 1, 2, 3, \dots, n\}$, x_k 出现的概率为 $P(x_k)$ 。 令延迟时间为 τ , 则负荷变为 $\{X_{1+\tau}, i = 1, 2, 3, \dots, n\}$, $X_{k+\tau}$ 出现的概率为 $P(x_{k+\tau})$ 。 x_k 和 $X_{k+\tau}$ 同时出现的联合概率为 $P(x_k, x_{k+\tau})$ 。 互信息函数为:

$$I(\tau) = \sum_{k=1}^n P(x_k, x_{k+\tau}) \ln \frac{P(x_k, x_{k+\tau})}{P(x_k)P(x_{k+\tau})} \quad (2)$$

τ 为用户信息函数的第一个极小值。

1.2 嵌入维数 m 的求取

笔者采用饱和关联维数法, 具体的方法是:

考察 m 维相空间中的一对相点

$$x(t_i) = (x(t_i), x(t_{i+\tau}), \dots, x(t_{i+(m-1)\tau})) \quad (3)$$

$$x(t_j) = (x(t_j), x(t_{j+\tau}), \dots, x(t_{j+(m-1)\tau})) \quad (4)$$

设它们之间的距离, 即欧式模为 $r_{ij}(m)$, 显然 $r_{ij}(m)$ 是相空间维数 m 的函数, 即

$$r_{ij}(m) = \|x(t_i) - x(t_j)\| \quad (5)$$

给定一个临界距离 r , 距离小于 r 的点对数在所有的点对中所占比例为 $C(r, m)$

$$C(r, m) = \frac{1}{N(N-1)} \sum_{i,j,i \neq j} H(r - \|x_i - x_j\|) \quad (6)$$

式中, N 为总相点数; $H(\cdot)$ 为 Heaviside 函数, 定义如下:

$$H(x) = \begin{cases} 1, & x > 0 \\ 0, & x < 0 \end{cases} \quad (7)$$

$C(r, m)$ 是一个积累分布函数, 它描写了相空间中的吸引子两点之间距离小于 r 的概率, 刻画了相对于相空间某参数点 $x(t_i)$ 在 r 内的相点聚焦的程度。 所以称 $C(r, m)$ 为吸引子的关联维数。 若 r 选得太小以致距离 $\|x(t_i) - x(t_j)\|$ 都比 r 大, 则 $C(r, m) = 0$, 表示相点分布在 r 范围之外; 若 r 选得太大, 一切点对的距离都不会超过它, 则 $C(r, m) = 1$ 。 所以 r 的选择不当反映不了系统内部的性质。 一般的说, r 的取法要使得 $0 \leq C(r, m) \leq 1$ 才有意义。

现在考察 $C(r, m)$ 和 r 的关系。 给定一个微量 δ , 用 δ 来探测吸引子的结构。 如果吸引子结构是一维的线型, 则在相对于参考点的距离在 r 以内的相关点数将近正比于 r/δ ; 如果吸引子中的结构是二维的面型, 则所对应的相关点数将正比于 $(r/\delta)^2$; 以此类推可知, 如果吸引子的结构是 D 维流型的, 则所对应的相关点数应正比于 $(r/\delta)^D$ 。 则 D 称为关联维数, 即

$$D = \lim_{r \rightarrow \infty} \frac{\ln C(r, m)}{\ln r} \quad (8)$$

随着嵌入维数 m 的升高, 根据式 (8) 求其关联维数, 当关联维数为 D_s 出现饱和现象时, 所对应的 m 就是需要选取的最佳嵌入维数 m_{opt} 。

2 BP 神经网络及其算法简介

神经网络是由大量类似于人脑最基本的处理单元——神经元广泛相互联接而构成的非线性复杂的智能网络系统, 它的特性和结构是神经元的特性和它们的互连方式决定的。BP 网络是一种多层前馈型网络, 典型的网络结构包括输入层、隐含层、输出层, 隐含层可有若干层。BP 神经网络的输入层和隐含层神经元采用 Sigmoid 函数, 输出层取 Sigmoid 函数或线性函数, 并采用纠错规则进行学习的网络。该网络具有并行分布结构。

BP 学习算法的基本思想就是采用有师学习。它并没有给出输入与输出间的解析关系, 它处理信息的能力主要在于网络中各个神经元之间的连接权系数值, 在给定大量的输入输出信号的基础上, 建立系统的非线性输入输出模型, 对数据进行大规模并

行处理, 通过网络输出误差的反向传播, 调整和修改网络的连接权值, 使误差达到最小, 其学习过程包括前向计算和误差反向传播。相应计算公式为:

$$y_h^k = f\left(\sum_{i=1}^{N_1} \omega_{hi} x_i^k + \theta_h\right) \quad (9)$$

输出层节点的输出为:

$$z_j^k = f\left(\sum_{h=1}^{N_2} \omega_{hj} y_h^k + \gamma_j\right) = f\left[\sum_{h=1}^{N_2} \omega_{hj} \cdot f\left(\sum_{i=1}^{N_1} \omega_{hi} \cdot x_i^k + \theta_h\right) + \gamma_j\right] \quad (10)$$

误差反向传播计算为:

$$E_k = \frac{1}{2} \sum_j (y_{jk} - O_{jk})^2 \quad (11)$$

其中 x_i 表示输入信号; y_h 表示隐层节点的输出; z_j 表示输出节点的输出; ω_{hi} 为输入节点到隐层节点的连接权值; ω_{hj} 为隐层节点到输出节点的连接权值; θ_h 为隐层节点阈值, γ_j 为输出节点的阈值; E_k 是第 k 个表征矢量的误差; y_{jk} 是第 j 个输出神经元的期望值; O_{jk} 是第 j 个输出神经元的实际值。

3 基于混沌时间序列和 BP 神经网络的负荷预测模型的建立神经网络

对于时间序列 $\{X_{i+\tau}, i = 1, 2, 3, \dots, n\}$, n 是序列的长度, 重构空间为: $X_i = (x_i, x_{i+\tau}, \dots, x_{i+(m-1)\tau})$ 。根据 Takens 的理论, 选取恰当的嵌入维数 m 和延迟时间 τ , 就会必然存在一个光滑的映射 F , 使得 $X_{i+1} = F(X_i), i = 1, 2, \dots, n$, 其中 F 为重构函数, $X_i = (x_i, x_{i+\tau}, \dots, x_{i+(m-1)\tau})$ 。同时由 Takens 的证明可知, 必然存在重构函数 f , 使得 $X_i = f(x_i, x_{i-\tau}, \dots, x_{i-(m-1)\tau})$, $i = 1 + (m-1)\tau, \dots, n-1, n$ 。使用 BP 神经网络泥河函数 $f(x_i, x_{i-\tau}, \dots, x_{i-(m-1)\tau})$ 作为 BP 神经网络的测试样本, x_{i+1} 就是仿真结果, 从 M 个相点中选取距离 $(x_i, x_{i-\tau}, \dots, x_{i-(m-1)\tau})$ 的空间欧式距离最近的 k 个相点作为预测 x_{i+1} 的训练样本。到此, 建立起基于混沌序列和 BP 神经网络的负荷预测模型。

4 实例分析

根据上述的方法, 笔者以某基地 2009 年 7 月 1 日 0: 00 至 2010 年 5 月 31 日 23: 00 的 8040 个有功负荷数据对 2010 年 6 月 1 日的 24 小时的有功负荷进行预测, 利用 Matlab 编程实现。如图 1, 采用互信息法计算延迟时间, 第 1 个极小值为 8, 故 $\tau=8$

为所求的延迟时间。根据饱和关联维数法, 如图 2, 计算得最优嵌入维数是 12, 即 $m=12$ 时, $E_1(d)$ 随 d 增加而趋于饱和。根据经验和误差分析选 $k=55$, 隐含层选为 6, 建立起基于混沌序列和 BP 神经网络的负荷预测模型。预测结果如表 1。相对误差分析如图 3, 可以看出, 相对误差均在 5% 以内, 误差在 1% 以内占 33.33%, 由此可见, 这种预测方法比较好。

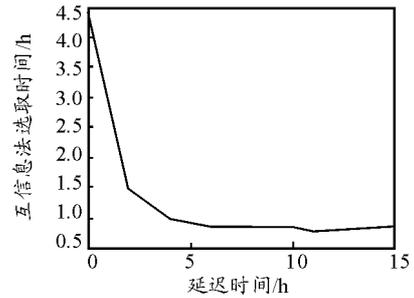


图 1 用互信息法计算延迟时间

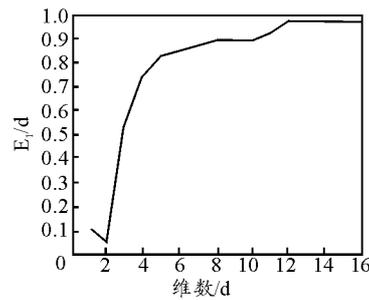


图 2 用饱和关联维数法计算最小嵌入维数

表 1 预测结果

时段	预测值/MW	实际值/MW	相对误差/%
1	1 514	1 516	-0.076 5
2	1 480	1 456	1.624 5
3	1 454	1 472	-1.245 8
4	1 467	1 494	-1.804 5
5	1 528	1 535	-0.468 9
6	1 564	1 555	0.589 7
7	1 637	1 572	4.158 9
8	1 545	1 586	-2.587 1
9	1 639	1 652	-0.784 5
10	1 708	1 702	0.365 2
11	1 793	1 743	2.856 4
12	1 650	1 631	1.147 5
13	1 575	1 603	-1.752 3
14	1 617	1 610	0.452 9
15	1 697	1 657	2.398 1
16	1 849	1 895	-2.429 6
17	1 982	1 965	0.841 9
18	2 016	2 015	0.042 9
19	1 980	2 059	-3.856 1
20	2 043	2 004	1.956 7
21	1 962	1 997	-1.758 6
22	1 988	1 957	1.596 4
23	1 736	1 708	1.652 8
24	1 554	1 573	-1.185 2

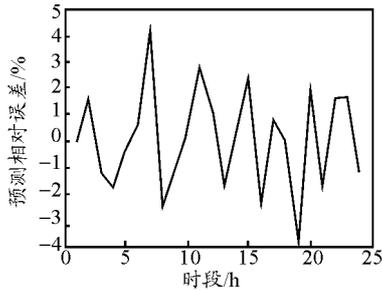


图 3 预测误差曲线

5 结束语

用混沌理论^[6-7]来进行短期电力负荷预测,是从序列自身找出内在的规律,避免了一些主观因素的影响,具有较高的可信度。实例仿真结果证明:基于混沌时间序列和BP神经网络相结合的电力短期负荷预测具有较高的预测精度。

(上接第 30 页)

```
muU=hatmusorted(975);
muL=hatmusorted(25);
hist(hatmusorted);
len=muU-muL;
```

其中 X 为试验记录结果,函数 Bootrsp 为自定义自助抽样函数,目前国外已有较多研究成果,具体可参见文献^[6-8]。上述代码最终可得到自助统计量分布柱状图以及置信区间宽度。为保密起见,只给出区间宽度,并将结果与正态分布假设所计算出的结果相比较,如表 1。可见,基于 Bootstrap 方法所得到的置信区间宽度略短。

表 1 2 种方法 3 项指标仿真所得置信区间宽度

指标名称	Bootstrap 方法 所得区间宽度	大样本统计法 所得区间宽度
潜艇目标发现率	0.083 9	0.097 4
浮标信号有效接收距离	0.230 3	0.242 1
某分机灵敏度	0.219 7	0.242 6

4 结束语

仿真实验证明: Bootstrap 方法有效克服了样本量少的问题,提高了区间精度,不仅可用在如潜艇目标发现率这类成败型指标上,在其它方面也有较大的应用价值。由于所有自助样本全部来源于原始

参考文献:

- [1] 牛东晓. 电力负荷预测技术及其应用[M]. 北京: 中国电力出版社, 1998.
- [2] 藤菲, 王宁. 一种应用时间序列技术的短期电力负荷预测模型[J]. 黑龙江电力, 2002(10).
- [3] 张亚军, 张大波, 许诚昕. 神经网络在电力系统短期负荷预测中的应用综述[J]. 浙江电力, 2007, 2(3): 5-9.
- [4] Park DC, et al. Electric load forecasting using artificial neural network [J]. IEEE Transactions on PWRs. 1991, 6(2).
- [5] 甘文泉, 王朝晖. 基于自适应模糊神经网络的电力短期负荷预测[J]. 西安交通大学学报, 2007, 31(9): 114-119.
- [6] 董双贵, 田聪, 朱建良. 基于混沌时间序列的电力月负荷预测[J]. 信息技术, 2006, 5(3): 132-134.
- [7] 杨红英, 叶昊, 王桂增. 混沌理论在电力系统负荷预测中的应用[J]. 继电器, 2005, 33(16): 26-30.

数据, 置信区间宽度不会降低很大, 因此, 如何将该方法其它考虑验前信息的统计方法结合使用, 将是下一步的研究方向。

参考文献:

- [1] 蔡洪, 张士峰, 张金槐. Bayes 试验分析与评估[M]. 长沙: 国防科技大学出版社, 2004: 71-73.
- [2] Manly B F J. Randomization and Monte Carlo methods in biology[M]. London: Chapman & Hall, 1991.
- [3] Noreen E W. Computer intensive methods for testing hypothesis: An introduction[M]. New York: John Wiley & Sons, 1989.
- [4] 刘文忠. 自助法统计推断的基本原理及应用[J]. 山西农业大学学报, 2004, 2(5): 164-165.
- [5] 盛骤, 谢式千, 潘承毅. 概率论与数理统计[M]. 北京: 高等教育出版社, 1988: 169-173.
- [6] Efron B. and Tibshirani R. An Introduction to the Bootstrap. London: Chapman & Hall, 1993.
- [7] Zoubir A M. Bootstrap: Theory and Applications. San Diego: Proceedings of the SPIE 1993 Conference on Advanced Signal Processing Algorithms, Architectures and Implementations. 1993: 216-235.
- [8] Zoubir A M and Boashash B. The Bootstrap and Its Application in Signal Processing[J]. IEEE Signal Processing Magazine. 1998, 5(1): 55-76.