

基于 RBFNN 的短期电力负荷混沌局域预测法

艾名舜¹, 马红光¹, 刘遵雄^{2,3}

(1. 第二炮兵工程学院 101 教研室, 陕西 西安 710025; 2 西安交通大学电子与信息工程学院, 陕西 西安 710049; 3 华东交通大学信息工程学院, 江西 南昌 330013)

摘要: 短期负荷序列数据表现出混沌特性, 可以使用混沌时序局域方法进行预测。在混沌时序重构相空间中预测中心相点和趋势相点之间的映射关系不是单纯的线性关系, 而常用的线性回归预测模型只能逼近线性映射。提出利用径向基函数神经网络 (RBFNN) 来建立预测模型, 可以更加精确逼近预测中心相点和预测相点之间的映射关系, 并用欧氏距离和关联系数联合方法选取近邻相点, 选取的近邻相点与预测中心相点的关联性更好。利用西北电网的负荷数据所做的实验证明, 本文提出的基于 RBFNN 的局域预测法比线性局域预测法获得了更为满意的预测精度。

关键词: 短期负荷预测; 混沌时序; 径向基函数神经网络; 局域模型

中图分类号: TM715 **文献标识码:** A **文章编号:** 1003-4897 (2006) 14-0024-04

0 引言

短期负荷预测是电力系统现代化管理的重要内容, 随着电力的市场化进程不断推进, 短期负荷预测在电力调度中的重要性也日益明显。电力负荷的变化受到多种因素的影响, 如气候、经济、人们的生活、工作习惯等, 而且这些因素也相互作用, 形成了一个复杂的非线性动力系统, 因此可以将短期负荷看成是复杂动力系统的一个状态变量。实际上, 短期负荷时序具有混沌特性已经得到证明^[1,2], 而基于混沌的预测方法在电力负荷预测方面的应用也取得了较好的效果^[3,4]。混沌局域预测法的核心思想是利用吸引子局部范围内近邻相点的相似性, 提取预测中心相点与预测点之间的映射关系, 进而得到预测数据。这种方法的关键是建立一个精确的模型来逼近预测中心相点与预测点之间的映射。目前常用的模型是线性回归模型, 这种模型的优点是计算简单, 在近邻点选择恰当的情况下可以有效逼近实际的线性映射; 缺点是回归模型对于受噪声干扰的近邻点比较敏感。更为重要的问题在于, 混沌系统的复杂性决定相点与预测点之间的映射关系不是单纯的线性关系, 而是线性和非线性关系兼而有之, 线性回归模型不能逼近非线性映射, 从而限制了这种模型的预测精度。我们提出利用径向基函数神经网络 RBFNN (Radial Basis Function Neural Network) 来建立局域预测模型, 这种模型具有强大的线性及非线性映射逼近能力, 通过对西北电网的短期负荷预测

试验, 结果表明基于 RBFNN 的局域预测方法可以获得较为满意的预测精度。

1 基于 RBFNN 的局域预测法

1.1 局域预测法

混沌时间序列在一维空间表现为复杂多变的混乱状态, 从而给直接预测带来极大困难。然而混沌序列在相空间中表现出较强的规律性, 相空间轨线围绕着吸引子演化, 轨线在局部具有自相似特性, 即相邻轨线的演化方向是相近的。从空间几何角度来看, 这种自相似性意味着其近邻相点内部有相同的映射关系:

$$f(x(n)) = f(x(n-1), x(n-2), \dots) \quad (1)$$

基于这一特性, 利用相邻轨线的演化过程来获得待预测点数据, 称之为混沌序列的局域预测。目前主要是利用线性回归模型来进行局域预测^[4], 就是将式 (1) 中的映射关系 f 视为线性关系, 但实际上这种假设并非处处成立的, 由于非线性系统的复杂性, 映射关系 f 应该非线性的或者两者兼有之。考虑到神经网络具有强大的线性和非线性函数逼近能力, 利用神经网络来建立预测模型能够更精确逼近 f , 从而提高预测的精度。该方法主要分为三个步骤: 1) 对时间序列进行相空间重构; 2) 选择预测中心点的近邻相点; 3) 将近邻相点作为训练样本训练 RBFNN, 得到预测模型。

1.2 相空间重构

无论利用何种模型进行局域预测, 恰当的相空间重构是保证预测精度的首要前提。Takens 定理

基金项目: 军队 2110 院校重点学科建设基金资助项目

证明^[6],如果嵌入维 $m \geq 2d + 1$ (d 是系统吸引子的维数),且其相应的延迟时间 τ 选择恰当,则可以利用时间序列在 m 维空间中重构吸引子,并且这个吸引子与原系统吸引子保持微分同胚。Packard等人提出了坐标延迟相空间重构方法^[7],其基本思想是确定一对恰当的嵌入维 m 和延迟时间 τ ,将一维的时间序列 $X = [x_1, x_2, \dots, x_N]$ 扩展成为 m 维相空间中的轨线 $\{Y_i\}$,每个相点为 $Y_i = [x_i, x_{i+\tau}, \dots, x_{i+(m-1)\tau}]$ 。

m 和 τ 的选择决定重构的吸引子与原系统的吸引子的相似程度,恰当地选择 m 和 τ 才能重构出与原系统微分同胚的吸引子,从而借助其研究原系统。因此确定最优的 m 和 τ 是相空间重构的关键问题。选择 m 和 τ 的方法主要分为两大类:第一类方法认为两者是独立的,可以分别求取,代表性的算法主要有有用自相关法、互信息法或平均位移法来确定 τ ,用 G-P法来确定 m ;第二类方法认为 m 和 τ 是相互关联的,要联合求取,这类方法有 C-C法及时间窗口法等。Takens证明了对于无限长且无噪声的时间序列,其 m 和 τ 是独立的,但工程中的时间序列都是有限长和有噪声的,因此应用第二类方法更合理。这里采用 G-P法^[8]和“平均位移法”迭代的方法来计算 m 和 τ ,可以认为这是一种嵌入维、延迟时间联合算法。其具体方法是:

1) 对于长度为 N 的时间序列,选择一个初始值,例如用自相关函数的第一个过零点位置作为的初始值,让嵌入维 m 在一定范围内变化,分别计算其对应的关联积分,计算公式为:

$$C(r) = \frac{1}{2M(M-1)} \sum_{i=1}^M \sum_{j=1}^i (r - |Y_i - Y_j|) \quad (2)$$

其中: $C(r)$ 是关联积分值, r 是阈值,一般可以在时间序列标准离差的1至3倍间变化, M 是相点数, $M = N - (m - 1)\tau$, $H(x)$ 是 Heaviside 函数。求取多条 $\ln(C(r)) - \ln(r)$ 曲线,每条曲线的无标度区间的斜率是 m 对应的关联维数 D , D 随 m 的增加而增加,直至饱和,此饱和值对应的 m 即为 τ 的初始值对应的嵌入维。

2) 利用上述求得的 m 作为初始嵌入维,令 τ 在一定范围内变化,计算平均位移量,其计算公式为:

$$S(m) = \frac{1}{M} \sum_{i=1}^M \left(\sum_{j=1}^{m-1} |x_{i+j} - x_i|^2 \right)^{\frac{1}{2}} \quad (3)$$

平均位移量描述的是相距为 τ 的时间点之间的平均距离,随着 τ 的增加,平均位移量的值会达到饱和,取 $S(m)$ 第一次达到饱和对应的 τ 为给定 m 相应

的延迟时间。

3) 将获得的 τ 代入第1步,再次计算 m ,依次循环,对于特定的时间序列,时间窗 $t_w = (m - 1) \cdot \tau$ 近似为一个常数,所以最终 m 和 τ 一定会收敛或接近收敛于 m_0 和 τ_0 ,我们利用这两个值来重构相空间吸引子。

1.3 近邻点的选择

近邻点的选取通常以欧氏距离为准则,但在相空间维数较高时,两相点间的欧氏距离较近并不能说明两者之间具有较强的相似性,由于局域预测法的关键是要利用近邻点之间的相似性,所以有必要利用另一种准则来选择最佳近邻点。关联系数是描述两序列相似性测度的标准统计量,可以反映两个相点向量的相似程度。为了保证选出的近邻点在预测中心点附近同时又有较好的相似度,这里采用欧氏距离和关联系数双重准则来选择近邻点,即在按照欧氏距离选取了若干个近邻点后再分别考察其与中心点的关联系数,然后从中选择关联系数较大的若干相点作为最优近邻点。设预测中心点和第 i 个近邻点分别为:

$$X_0 = (x_0(t), x_0(t-\tau), \dots, x_0(t-(m-1)\tau))$$

$$X_i = (x_i(t), x_i(t-\tau), \dots, x_i(t-(m-1)\tau))$$

其均值分别为

$$m_0 = \frac{1}{m} \sum_{k=0}^{m-1} x_0(t-k\tau), \quad m_i = \frac{1}{m} \sum_{k=0}^{m-1} x_i(t-k\tau)$$

关联系数的计算公式为:

$$r(X_0, X_i) = \frac{\sum_{k=0}^{m-1} (x_0(t-k\tau) - m_0)(x_i(t-k\tau) - m_i)}{\sqrt{\sum_{k=0}^{m-1} (x_0(t-k\tau) - m_0)^2 \sum_{k=0}^{m-1} (x_i(t-k\tau) - m_i)^2}} \quad (4)$$

欧氏距离和关联系数双重准则保证了选出的最优近邻点与预测中心点有相似的内部映射关系。选择近邻点作为训练样本和选择相似日预测短期电力负荷在原理上是一致的,只是后者主观性比较强。

1.4 径向基函数神经网络

混沌序列的局域预测问题上,近邻相点及其未来趋势相点之间的映射关系往往不是单纯的线性关系,所以线性模型不能完全反映这种映射。人工神经网络的线性及非线性映射逼近能力已经在理论及工程实践中得到证明,所以利用人工神经网络建立预测模型是更好的选择。这里我们选择了径向基函数神经网络 RBFNN (Radial Basis Function Neu-

ral Network) [9]。

RB FNN 结构为单隐层的三层前向网络结构。其输入层和输出层的神经元数目与相应的样本维数相同;隐层神经元数目根据任务要求而定,有自动算法而不需要事先确定。从输入层到隐层的映射关系是非线性的,隐层的神经元激活函数即 RBF,是相对中心点径向对称衰减且高次可导的非负函数,一般采用高斯函数或升余弦函数等。隐层到输出层是线性的映射关系,网络输出是隐层输出的线性加权和。RB FNN 输出可以表示为:

$$Y = \text{purlin} \left(\sum_{i=1}^K (w_{ij} \times \text{radbas}(W_i - X \times b_1) + b_2) \right) \quad (5)$$

其中: purlin 和 radbas 分别是输出层和隐层神经元的激活函数,前者为线性函数,后者为 RBF; w_{ij} 和 b_2 是线性权值和阈值, W_i 和 b_1 是 RBF 中心点和控制其支集范围的参量。

目前 RB FNN 的训练方法主要是两段训练法:首先用基于 Bayes 理论的聚类的方法确定径向基函数中心及其支集范围,然后用最小二乘法、卡尔曼滤波等其他方法训练连接权 [10]。由于没有误差反向传递的过程, RB FNN 训练速度快,对噪声样本不敏感,并且不存在局部最小问题,这是 RBF 网络的主要优势所在。

正确的相空间重构,优化的近邻点选择加上 RBF 神经网络,构成了一个完整的混沌序列预测流程,实践证明了该方法是有效的。

2 电力负荷预测实例分析

数据采用西北电网 2005 年 3 月 1 日至 5 月 27 日共 88 天的负荷曲线,每个点为每小时负荷均值。

利用 G-P 法和“平均位移法”迭代的方法,反复求取负荷序列的饱和关联维对应的嵌入维和饱和平均位移量对应的延迟时间,发现二者收敛于 ($m = 6, \tau = 2$),重构的吸引子在三维空间的投影如图 1 所示。

恰当地选取嵌入维数和延迟时间,使一维呈混沌状态的负荷序列数据在高维空间表现出很强的规律性,从而为较精确的预测提供了良好的前提条件。确定一个预测中心点之后,首先按照欧氏距离准则在相空间中找出其 60 个近邻相点,再根据关联系数准则选出前 20 个与中心点相似性最好的相点作为最佳近邻点。近邻点的数目与已知数据的规模有关,而且基于神经网络的局域预测模型对于近邻点数目不敏感,因此可根据实际情况来确定之。将近

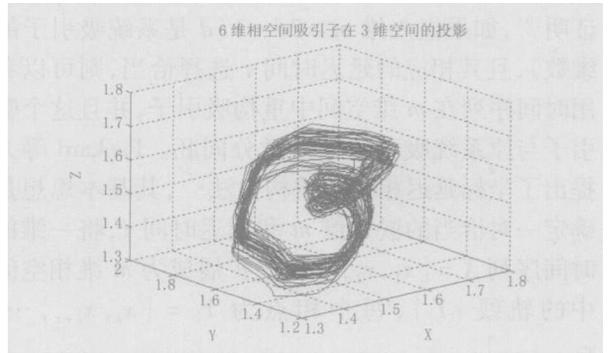


图 1 2005 年春季西北电网负荷三维相空间图 ($m = 6, \tau = 2$)

Fig 1 Three-dimension reconstruction for the load series in Northwest Power Grid ($m = 6, \tau = 2$)

邻点写成训练样本格式 $Y_i = [P_i, T_i]$, 其中 $P_i = [x_i, x_{i+1}, \dots, x_{i+5}]$, $T_i = x_{i+6}$, 用训练样本来训练 RB FNN, 得到预测器模型。本文方法仍属于单步预测, 每预测一步后将得到的数据作为已知数据预测下一步。

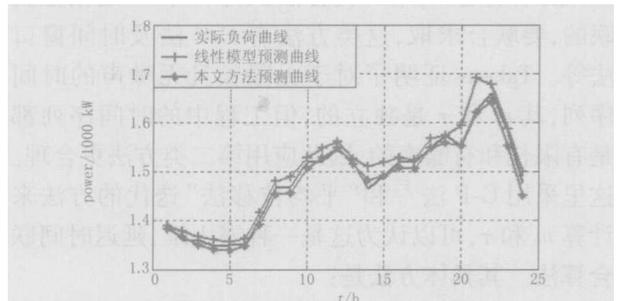


图 2 24 h 预测效果比较图

Fig 2 Load values for one day with two approaches

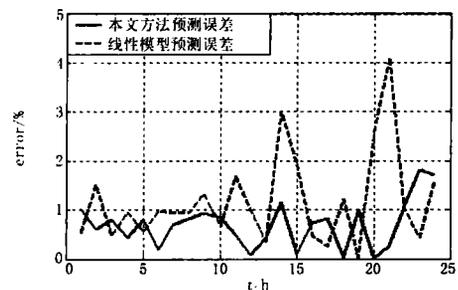


图 3 24 h 预测误差比较图

Fig 3 APE for 24 hours one day with two approaches

分别利用本文方法和线性模型方法对 2005 年 5 月 21 日的 24 h 负荷做预测, 其预测效果如图 2 所示, 其中实线代表实际的电力负荷数据, ‘—*’ 代表本文方法预测数据, ‘—+’ 代表线性模型预测数据。图 3 是两种预测方法的预测误差曲线, 其误差用点绝对百分误差 APE (absolute percent error) 表示, 观察该图可以发现, 预测误差有随时间逐渐增大的趋势, 而

本文方法预测误差整体上明显小于线性模型预测误差,前者平均误差为 0.7%,后者为 1.19%。

实验结果表明,基于 RBFNN 的预测模型是可行的,而且比一般线性预测模型的预测精度更高。为了进一步显示预测方法的实用性,对该电网 2005

年 5 月 21 日至 27 日的负荷数据进行预测,结果如表 1 所示。表中数据为误差位于所给范围的点占一天预测点数的百分比例,M1 为文中预测方法结果,M0 为线性模型预测结果。

表 1 两种方法预测结果比较

Tab 1 Prediction results with two approaches

误差		5月 21日	5月 22日	5月 23日	5月 24日	5月 25日	5月 26日	5月 27日	平均
<2%	M1	100	95.8	79.2	83.3	54.2	91.7	87.5	84.5
	M0	82.5	95.8	87.5	83.3	33.3	50	83.3	73.7
2%~3%	M1	0	0	12.5	16.7	29.2	8.3	8.3	10.7
	M0	4.2	4.2	12.5	16.7	33.3	25	8.3	14.9
>3%	M1	0	4.2	8.3	0	16.7	0	4.2	4.8
	M0	8.3	0	0	0	33.3	25	8.3	10.7

3 结论

本文的预测方法主要分为三个部分:相空间重构、选择最优近邻点和建立基于 RBFNN 的预测模型。其中,建立基于 RBFNN 的预测模型是最关键的一步,实验结果表明,这种模型的预测效果优于一般的线性预测模型。

参考文献:

- [1] 杨正瓴,林孔元. 电力系统负荷记录混沌特性成因的探讨[J]. 电力系统自动化, 2002, 26(10): 18-22
YANG Zheng-ling, L N Kong-yuan Discussion on Cause of Chaos in Load Records of Power Systems[J]. Automation of Electric Power Systems, 2002, 26(10): 18-22
- [2] 李眉眉,丁晶. 电网短期负荷预测的混沌方法[J]. 四川电力技术, 2005, 28(4): 7-10
LIMEimei, DNG Jing Short Term Load Forecasting Using Chaotic Method[J]. Sichuan Electric Power Technology, 2005, 28(4): 7-10
- [3] 岳毅宏,韩文秀,张伟波. 基于关联度的混沌序列局域加权线性回归预测法[J]. 中国电机工程学报, 2004, 24(11): 17-20
YUE Yi-hong, HAN Wen-xiu, ZHANG Wei-bo Local Adding-weight Linear Regression Forecasting Method of Chaotic Series Based on Degree of Incidence [J]. Proceedings of the Chinese Society for Electrical Engineering, 2004, 24(11): 17-20
- [4] 吕金虎,张锁春. 加权一阶局域法在电力系统短期负荷预测中的应用[J]. 控制理论与应用, 2002, 19(5): 767-770
L Ü Jin-hu, ZHANG Suo-chun Application of Weighted Linear Local Method in Electric Power System Short-term Load Forecasting [J]. Control Theory and Applications,

2002, 19(5): 767-770

- [5] 雷绍兰,孙才新,周泉,等. 电力短期负荷的多嵌入维一阶局域预测[J]. 电网技术, 2005, 29(13): 45-49
LEI Shao-lan, SUN Cai-xin, ZHOU Quan, et al Short Time Load Forecasting Using One-rank Local-region Method in Multi-dimension Embedding Phase Space [J]. Power System Technology, 2005, 29(13): 45-49
- [6] Takens F. Detecting Strange Attractor in Turbulence[J]. Lecture Note in Mathematics, 1981, 898(2): 361-381.
- [7] Packard N H, Crutchfield J P, Farmer J D, et al Geometry from a Time Series [J]. Phys Rev Lett, 1980, 45(3): 712-716
- [8] Grassberger P, Privacies I Characterization of Strange Attractors [J]. Physical Review Letters, 1983, 50(5): 346-349.
- [9] Broomhead D, Lowe D. Multivariable Function Interpolation and Adaptive Networks [J]. Complex Systems, 1988: 321-355.
- [10] 侯秋香. RBF神经网络混合学习算法研究及应用(硕士学位论文) [D]. 哈尔滨: 哈尔滨工业大学, 2004
HOU Qiu-xiang Research and Application of Mixed Learning Arithmetic on RBF Neural Networks, Thesis [D]. Harbin: Harbin Institute of Technology, 2004

收稿日期: 2006-01-18; 修回日期: 2006-03-28

作者简介:

艾名舜(1981-),男,硕士研究生,研究方向为信号与信息处理; E-mail: mingshunai@163.com

马红光(1959-),男,教授,博士生导师,研究方向为信号与信息处理,信息安全,现场总线;

刘遵雄(1967-),男,在职博士生,副教授,专业方向为信号与信息处理。

(下转第 34 页 continued on page 34)

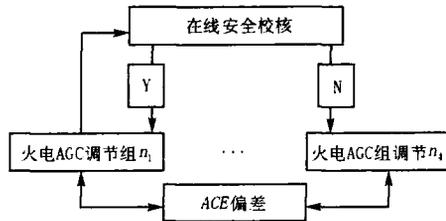


图 2 火电 AGC 编组调整流程

Fig 2 Adjusting strategy of thermal power AGC

节性能,同时也提高了整个 AGC 系统的调节性能。调整流程如图 2 所示。

在以上调整过程中,应严格进行安全校核,当 n_i 组中某机组出力的加减将引起省网某断面的过载,则此时该机组出力维持不变,其相应增加量可由本组其余机组承担或转由其余组承担。

4 结语

综上所述,随着适应 CPS 考核标准及满足河南电网实际情况 AGC 控制策略实施以来,大大改善了河南电网 AGC 调节品质,提高了河南电网频率品质,减少了联络线责任考核电量。实践证明该 AGC 控制策略在河南电网的应用是有效和成功的。

AGC control strategy based on CPS standard in Henan Power Grid

HU Yang-yu, LI Da-peng, WANG Zi-qi, ZHANG Jian-li

(Henan Electric Power Dispatching and Communication Center, Zhengzhou 450052, China)

Abstract: Under the control performance standard (CPS) and current level of AGC in Henan Power Grid, this paper corrects and extends the AGC control strategy based on A1/A2 standard to satisfy the CPS detailed rules that is being used in Huazhong Power Grid. The strategy includes dynamic AGC control strategy based on pre-day plan, thermal-hydro proportion in taking on ACE and alignment strategy of thermal power AGC. The three strategies improve the AGC adjusting performance and frequency quality in Henan Power Grid.

Key words: AGC; super short time load forecasting; thermal-hydro coordination

参考文献:

- [1] Policy F-Generation Control and Performance. NERC Operation Manual [EB/OL]. <http://www.nerc.com>. 1997.
- [2] 华中电网省(市)间联络线电力电量管理考核办法(试行)[Z]. 2005. Management Check Method of Tie Line Quantity of Electricity of Central China Power Grid (pilot) [Z]. 2005.
- [3] 钱玉妹,崔恒志,等. 适应 CPS 标准的 AGC 系统设计与应用[J]. 电力系统自动化, 2003, 27(11): 69-70. QIAN Yu-shu, CUI Heng-zhi, et al Design and Application of Automatic Generation Control System Adapting to CPS Standard [J]. Automation of Electric Power Systems, 2003, 27(11): 69-70.

收稿日期: 2006-01-03; 修回日期: 2006-02-16

作者简介:

胡扬宇(1978-),男,硕士,工程师,从事电力系统运行与控制研究工作; E-mail: flyjoke@v86.net

李大鹏(1973-),男,高级工程师,从事电力系统运行与控制研究工作;

王子琦(1974-),男,高级工程师,从事电力系统运行与控制研究工作。

(上接第 27 页 continued from page 27)

Chaotic load series local forecasting based on RBFNN

AI Ming-shun¹, MA Hong-guang¹, LI Zun-xiong^{2,3}

(1. The Second Artillery Engineering Institute, Xi'an 710025, China;

2. School of Electronics and Information Engineering, Xi'an Jiaotong University, Xi'an 710049, China;

3. School of Information Engineering, East China Jiaotong University, Nanchang 330013, China)

Abstract: Short-term load series possess the chaotic characteristic, and can be forecasted with chaotic series local model. The mapping between prediction phase point and future counterpart point is not absolute linear, but the common linear regression models can only approximate linear mapping. The paper puts forward a novel model based on Radial-Basis-Function Neural Network (RBFNN), which has higher performance on approximating the real mapping, and both Euclidian distance and correlative coefficients approaches are employed to select the neighbourhood phase points, which are more close to the prediction point. The experiment with load series with 24 points one day from Northwest Power Grid demonstrates that the novel model achieves better prediction precision than the linear model.

Key words: short-term load forecasting; chaotic time series; RBFNN; local model