

Short-Term Load Forecasting Based on RBF Adaptive Neural Fuzzy Inference

Xiao-kan Wang¹, Lei Wang¹, Zhong-liang Sun¹, Dong-qing Feng²

1. Henan Mechanical and Electrical Vocational Group, Zheng zhou, China;

2. Institute of Information and Control in Zheng zhou University, Zheng zhou, China

1. e-mail wxkbbg@163.com, 2. e-mail dqfeng@zzu.edu.cn

Abstract: According to historical load datas of Dong Guan grid, by which analyze this area's power load characteristic and consider load forecasting influence factors such as the date type, temperature, weather conditions in the first. In view of the load has a certain objective laws, but which has a lot of randomness and uncertainty, applying one kind new based on the RBF (Radial Basis Function) Neural Fuzzy Inference to carry on short-term load forecasting. By programming with MATLAB to carry on short-term power system load forecasting, carry on the short-term load forecast experiment to the Dong Guan grid and draw the forecasting result curves. The result indicated that the RBF Adaptive Neural Fuzzy Inference of the forecast accuracy is satisfied with the verification of this method is effective and practical.

Keywords: short-term load forecasting; RBF neural network; Adaptive Neural Fuzzy Inference; MATLAB

基于 RBF 自适应神经模糊推理的短期电力负荷预测

王晓侃¹, 王蕾¹, 孙忠良¹, 冯冬青²

1 河南省机电职业教育集团, 郑州, 中国, 450002; 2 郑州大学信息与控制研究所, 郑州, 中国, 450001

1. e-mail wxkbbg@163.com, 2. e-mail dqfeng@zzu.edu.cn

【摘要】根据东莞电网的历史负荷数据, 分析该地区电力负荷的特性, 考虑日期类型、温度、天气状况等影响负荷预测的因素; 针对负荷具有一定的客观规律, 但又具有很大的随机性和不确定性, 提出一种新型基于径向基函数 (Radial Basis Function) 的自适应神经模糊推理的方法进行短期负荷预测。用 MATLAB 编制电力系统短期负荷预测程序, 并绘制预测结果曲线。结果表明基于 RBF 自适应神经模糊推理的预测精度是满意的, 验证了本方法的有效性和实用性。

【关键词】短期负荷预测; RBF 神经网络; 自适应神经模糊推理; MATLAB

1 引言

本电力系统负荷预测是实现电力系统安全、经济运行的基础。对一个电力系统而言, 提高电网运行的安全性和经济性, 改善电能质量, 都依赖于准确的负荷预测。电力系统在逐步发展、完善过程中, 负荷预测已成为能量管理系统(EMS)中一项独立的内容, 在当前电力系统市场化的必然趋势下, 负荷预测已成为电力市场交易管理系统中必不可少的一部分。在实际应用中, 电力系统不同组成部分对负荷预测的范围和精度有所不同, 因此研究负荷变化的内在规律和负荷特性、影响负荷变化的各种相关因素以及各种相关因素在预测如何进行规范化处理对提高预测精度及负荷预测的发展有重要的意义^[1-3]。

2 基于 RBF 自适应神经模糊推理(ANFIS)方法

2.1 基于 RBF 的 ANFIS 结构描述和学习算法

2.1.1 基于 RBF 的 ANFIS 结构描述

Sugeno 模糊模型中的一条典型模糊推理规则为:

if x is A and y is B then $z=f(x, y)$

其中: A 和 B 作为前提的模糊数, $z=f(x, y)$ 为结论中的精确数。通常 $f(x, y)$ 为 x 和 y 的多项式。与之相对应, Roger Jang 提出与一阶 Sugeno 模糊模型功能等同的基于自适应神经网络的模糊推理系统用来实现 Sugeno 模糊模型的学习过程。可以认为是 Sugeno 型模糊模型的神经网络实现, 该网络是一个多层前馈网络, 结构如图

1 示^[9,13-14]。

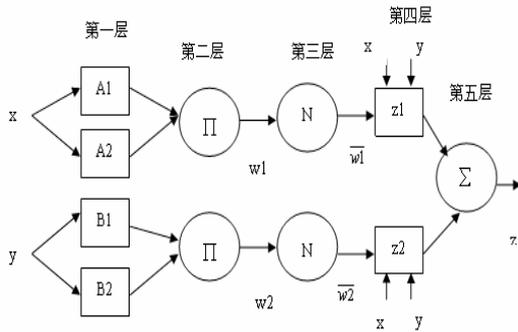


图 1. ANFIS 结构图
Figure 1. Structure of ANFIS

图中输入向量为[x, y]，权重 w1 和 w2 通常由前提中的隶属函数召值乘积得来，输出 f 为各规则输出的加权平均，w1 和 w2 为各权重在总权重中的比例。同一层节点都具有相同的输出函数。

由上图可知，ANFIS 模型结构分为：计算输入的模糊隶属度，每条规则的适用度，适用度的归一化，每条规则的输出，整个模糊系统的输出等五层，输入层直接将输入值送到下一层，模糊化层的输出是一个隶属函数，它与模糊推理前提条件中的基本模糊状态相对应，模糊推理层联系着模糊推理的前提和结论，反模糊化层是给出确定的输出让系统去执行。各层之间的连接权系数通过给定样本数据进行自适应的调节，使所得到的结构很好的反应实际系统的模型。整个网络结构详细描述如下^[9]：

第一层：模糊化层；它负责输入信号的模糊化，节点 i 具有输出函数：

$$O_i^1 = \mu_{A_i}(x)$$

其中：x 是节点 1 的输入， A_i 是模糊集。 O_i^1 就是 A_i 的隶属函数值，表示 x 属 A_i 的程度。本文选取 $\mu_{A_i}(x)$ 为钟形函数，且具有最大值 1 或 0，即：

$$\mu_{A_i}(x) = \frac{1}{1 + \left[\frac{(x - \gamma_i)^2}{\alpha_i} \right]^{\beta_i}}$$

这里 $\{\alpha_i, \beta_i, \gamma_i\}$ 为前提参数，其中， α_i 为宽度， β_i 为斜率， γ_i 为中心位置，通过调整这些参数，隶属函数的形状就会发生变化。实际上这里的隶属函

数可以取任意分段连续函数，比如梯形函数或高斯型函数等。

第二层：该层为规则的释放强度层；这一层的节点负责将输入信号相乘。如：

$$w_i = \mu_{A_i}(x) \times \mu_{B_i}(y) \quad i=1,2$$

每个节点的输出代表一条规则的可信度。这里的“×”可以是任何满足 T 规范的 AND 算子。通过此运算，确定了每个模糊规则的激活强度。

第三层：所有规则强度的归一化层；其中第 i 个节点计算第 i 条规则的归一化可信度为：

$$\bar{w}_i = \frac{w_i}{w_1 + w_2} \quad i=1,2$$

该层每个节点为圆节点(固定节点)，计算模糊规则的权系数，对模糊规则的激活强度进行归一化操作。

第四层：模糊规则的输出层；该层计算模糊规则的输出结果，其中的每个节点都是一个自适应节点。第 i 个节点具有输出：

$$O_i^4 = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + \gamma_i)$$

这里， \bar{w}_i 为第三层的输出， $\{p_i, q_i, \gamma_i\}$ 为结论参数。

第五层：解模糊层；该层只有一个圆节点，它的输出是所有输入信号的和，也就是模糊推理的结果：

$$O_i^5 = \sum_i \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i}$$

因此，在给定前提参数(初始隶属函数)后，ANFIS 的输出可以表示为结论参数的线性组合：

$$f = \frac{w_1}{w_1 + w_2} f_1 + \frac{w_2}{w_1 + w_2} f_2 = \bar{w}_1 f_1 + \bar{w}_2 f_2 = (\bar{w}_1 x) p_1 + (\bar{w}_1 y) q_1 + (\bar{w}_1) \gamma_1 + (\bar{w}_2 x) p_2 + (\bar{w}_2 y) q_2 + (\bar{w}_2) \gamma_2$$

推论可知，对于具有 m 个输入变量，每个输入 k 个模糊集的 Sugeno 模糊模型，可以按照上述方法转化为神经网络结构，其控制规则总数为： $n = K^m$ 。

2.1.2 基于 RBF 的 ANFIS 学习算法

神经模糊控制器的主要作用是应用神经学习技术，调整神经模糊控制系统的参数和结构。模糊控制器需要两种类型的调整：结构调整和参数调整；结构调整包括变量数目、输入输出变量的论域划分、规则数目等。一旦获得了满意的结构后，就需要对参数进

行调整。参数调整包括与隶属函数有关的参数，如中心、宽度、斜率等的调整。由于网络结构已经确定，的学习算法实际上只是对控制器的参数进行学习，只需调整前提参数和结论参数。当前主要有多种方法来更新 ANFIS 参数：本文的 ANFIS 的学习方法采用了梯度下降和最小二乘的混合算法。此算法综合运用梯度法和最小二乘法(LSE)来辨识参数，对前提参数运用梯度下降法，对结论参数运用最小二乘法。学习过程分为前向学习和反向学习，前向学习到 ANFIS 的第四层，结论参数 $\{p_i, q_i, \gamma_i\}$ 由最小二乘估计法求得。通过反向学习的梯度下降法 (gradient-descent-approach)，固定输出层参数不变，向减少误差的方向对输入层或中间层的参数进行自寻优调整，通过返回误差的变化率来改变前提参数 $\{p_i, \alpha_i, p_i, \gamma_i\}$ 改变隶属函数的形状，直到整个样本集的均方差达到规定的精度要求。

3 电力负荷预测结果及分析

短期负荷预测的一个突出特点是：为对系统负荷进行预测，必须对过去的负荷历史资料进行分析。因为电力系统的负荷本质上是不可控的，了解未来短期内的负荷的可能变化的一个最有效的办法就是，观察负荷的历史纪录。因此考虑负荷变化的日、周等周期性以及影响负荷变化的天气因素，总结负荷变化的规律性，并根据负荷的这些特性应用基于 RBF 自适应神经模糊推理的方法进行短期负荷预测,并应用 MATLAB 进行预测仿真^[4]。

3.1 负荷预测时神经网络隐含层节点的确定

本文的预测模型采取的是基于 RBF 自适应神经模糊推理模型，根据电力负荷的特点，将日期类型分为 4 类：周一，工作日（周二到周五），周六，周日，对一天 24 个小时的日负荷进行预测，因此我们总共建立了 96 个神经网络模型。输入节点一共是 96 个，分别取的是预测日前一天、前两天、前一一周的同一时刻及前一天前一个时刻、前两个时刻的历史负荷数据和预测日以及预测日前一天的最高温度、最低温度，预测日的天气状况的度量值和预测日的日期类型变量；输出节点是 1 个，就是预测日的整点负荷值。由上面可知，本文隐含层数目是采取试验的方法取得的，随机对某地区电网一天 24 个小时的负荷进行预测，预测结果的相对误差如图 2 所示。

由图 2 可见，隐层神经元数目的不同，预测结果的相对误差各不相同，隐层神经元数为 8 时，预测结

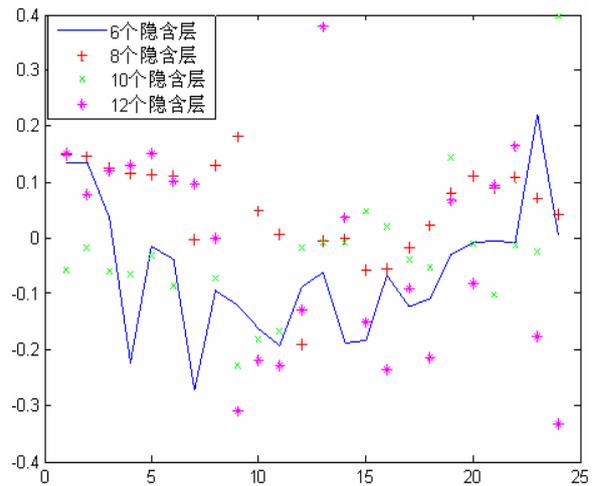


图 2. 隐层神经元数目不同的预测误差曲线图
Figure 2. Hidden layer neurons in the number of different forecasting error curves

果的平均相对误差达到最小。这是我反复试验中的任意一个预测结果，在这由于篇幅的限制就不多列举其它的预测结果了，由此本文确定了隐层神经元数目为 8 个。

3.2 负荷预测方法的比较

本文采用 BP 神经网络算法、RBF 网络神算法和基于 RBF 自适应神经模糊推理三种方法对东莞电网 2005 年 01 月 08 日的负荷进行了预测，对日负荷值和相对误差进行了比较，结果见图 3 和表 1。

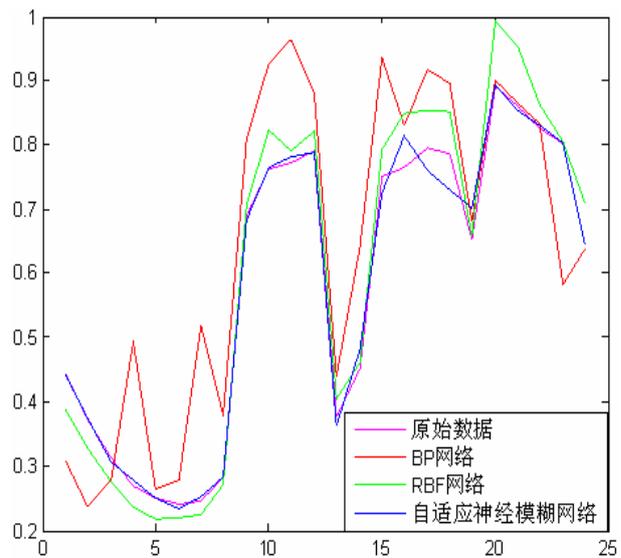


图 3. BP 神经网络算法、RBF 神经网络算法和 RBF 自适应神经模糊控制算法预测结果曲线图
Figure 3. Bp and RBF Neural Networks Algorithm and RBFANFIS forecasting curves

表 1 不同预测方法的预测结果比较
Table 1. Forecasting results comparison based on different forecasting techniques

整点值	原始数据	BP神经网络		RBF神经网络		自适应神经模糊推理	
		预测值	误差	预测值	误差	预测值	误差
1	0.3724	0.2368	0.1356	0.3275	0.0499	0.3754	0.0030
2	0.3143	0.2784	0.0359	0.2752	0.0391	0.3069	0.0074
3	0.2696	0.4939	0.2243	0.2362	0.0334	0.2778	0.0082
4	0.2495	0.2646	0.0151	0.2184	0.0311	0.2303	0.0008
5	0.2399	0.2775	0.0376	0.2201	0.0198	0.2333	0.0066
6	0.2464	0.5193	0.2729	0.2238	0.0226	0.2521	0.0057
7	0.2840	0.3794	0.0954	0.2720	0.0120	0.2826	0.0014
8	0.6894	0.8101	0.1207	0.7054	0.0160	0.6287	0.0067
9	0.7631	0.9626	0.1635	0.8238	0.0607	0.7658	0.0027
10	0.7717	0.9642	0.1925	0.7905	0.0188	0.7811	0.0094
11	0.7915	0.8788	0.0873	0.8202	0.0287	0.7880	0.0035
12	0.3768	0.4389	0.0621	0.4049	0.0281	0.3628	0.0140
13	0.4519	0.6405	0.1866	0.4615	0.0096	0.4811	0.0292
14	0.7519	0.9347	0.1828	0.7935	0.0416	0.7251	0.0268
15	0.7642	0.8307	0.0665	0.8492	0.0850	0.8152	0.0510
16	0.7949	0.9177	0.1228	0.8546	0.0597	0.7611	0.0338
17	0.7860	0.8950	0.1090	0.8520	0.0660	0.7288	0.0572
18	0.6515	0.8610	0.0295	0.6578	0.0063	0.7011	0.0496
19	0.8918	0.9005	0.0087	0.9918	0.1000	0.8934	0.0016
20	0.8597	0.9603	0.0066	0.9550	0.0953	0.8538	0.0059
21	0.8253	0.9329	0.0076	0.8632	0.0379	0.8095	0.0042
22	0.8031	0.5819	0.2212	0.8055	0.0024	0.8016	0.0015
23	0.6430	0.6394	0.0036	0.7097	0.0667	0.6437	0.0007
24	0.4444	0.3096	0.1348	0.3876	0.0568	0.4430	0.0014

由表 1 可以看出，BP 神经网络的预测误差最大值为 0.2729，RBF 神经网络的预测误差最大值为 0.1，RBF 自适应神经模糊控制的预测误差最大值为 0.0572，可见其 RBF 自适应神经模糊控制的相对误差最小，证明了自适应神经模糊控制有效的提高了负荷预测的精度，达到了实际运行的需要。

4 结论

基于 RBF 自适应神经模糊推理方法具有收敛速度快，拟合能力强，预测精度高，训练结果唯一等优点，

将其应用于东莞地区的短期电力负荷预测，用 MATLAB 编程仿真，结果表明基于 RBF 自适应神经模糊推理的短期电力负荷预测结果与实际情况比较吻合，取得了满意的效果。

References (参考文献)

- [1] Chongqing Kang, Jie Xia, Mei Liu. Power System Load Forecasting [M]. Beijing: China Electric Power Press, 2007. 康重庆, 夏清, 刘梅编著. 电力系统负荷预测[M]. 北京: 中国电力出版社, 2007.
- [2] Guoquan Xiao. Power Load Forecasting [M]. Beijing: China Electric Power Press, 2001. 肖国泉等编著. 电力负荷预测[M]. 北京: 中国电力出版社, 2001.
- [3] Xizheng Zhao. Analysis and Forecasting of China Power Load Characteristics[M]. Beijing: China Electric Power Press, 2002. 赵希正等编著. 中国电力负荷特性分析与预测[M]. 北京: 中国电力出版社, 2002.
- [4] Passino Kevin M. Fuzzy Control [M]. Beijing: Tsinghua Publishing House, 2001.
- [5] Dongqing Feng, Songhe Xie. fuzzy. Fuzzy Intelligent Control [M]. Beijing: Chemical Industry Press, 2000. 冯冬青等编著. 模糊智能控制[M]. 北京: 化学工业出版社, 2000.
- [6] Fei Guo. Research on the RBF Fuzzy-Neural Network and Application on the Unit Coordination Control System [D] Beijing: North China Electric Power University.2002.5. 郭飞. RBF 模糊神经网络的研究及其在单元机组协调控制系统中的应用[D]. 北京: 华北电力大学, 2002. 5.
- [7] Yanxin Li. An Algorithm for Automatically Extracting Fuzzy Rules Based on RBF Neural Network [D] Dalian: DaLian Jiaotong University. 2005. 5. 李延新. 一种基于 RBF 神经网络自动提取模糊规则的方法研究[D]. 大连: 大连交通大学, 2005. 5.
- [8] Gang Guo. Research on Adaptive Neural Network Fuzzy Control Strategy in the Inverted Pendulum [D] Taiyuan: Taiyuan University of Technology. 2004. 5. 郭刚. 自适应神经模糊控制策略在倒立摆系统中的研究[D]. 太原: (48)太原理工大学, 2004. 5.
- [9] Austrom. K. J Direction in Intelligent Control[J]. Plenay session IFAC International Symposium 1991(2): 15-17.
- [10] Jyh-Shing. Roger. Jang. "ANFIS: Adaptive Neural-Network based Fuzzy Inference System"[J]. IEEE Trans on Systems, Man and Cybernetics, 1993, 23(3): 6-9.
- [11] J. Sola, J. Sevilla. Importance of Input Data Normalization for the Application of Neural to Complex Industrial Problems. IEEE Transaction on Nuclear Science, Vol.44, No.3, June 1997.
- [12] E. H. Mamdani. Application of Fuzzy Algorithms for Control of Simple DynamicPlant. IEE Control and Science, 1974, 121(12): 1585-1588.
- [13] C. C. Lee. Fuzzy Logic in Control Systems: Fuzzy Logic Controller-Part I& Part II .IEEE Trans. Syst., Man, Cybern., 1990, 20(2): 404-435.