

一种基于 RBF 自适应神经模糊推理的短期 电力负荷预测方法

王晓侃^{1,2} 王琼²

(1 北京交通大学 电子信息工程学院,北京 100044; 2 河南机电职业学院,新郑 451191)

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征,综合分析天气、温度、日期等因素对电力负荷预测的影响。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,提出了一种新型基于径向基函数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令人满意的,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

中图分类号 TP273 **文献标识码** A **文章编号** 1672-4321(2018)03-0112-04

Short-term Load Forecasting Method Based on RBF Adaptive Neural Fuzzy Inference

Wang Xiaokan^{1,2}, Wang Qiong²

(1 School of Electronic and Information Engineering, Beijing Jiaotong University, Beijing 100044, China;

2 Henan Mechanical and Electrical Vocational College, Xinzheng 451191, China)

Abstract According to the historical load data of Dongguan grid, power load characteristic in this area is analyzed and the load forecasting influence factors such as the date type, temperature, weather conditions are also analyzed. In view of the load has a certain objective laws, it also has a lot of randomness and uncertainty, a neural fuzzy inference to carry on short-term load forecasting based on RBF is proposed. The program that carries on short-term power system load forecasting is designed in MATLAB, forecasting result curves are drawn. The results indicate that the RBF adaptive neural fuzzy inference of the forecast accuracy is satisfied, so the given method is effective and practical.

Keywords short-term load forecasting, RBF neural network, adaptive neural fuzzy inference

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]。

1 基于 RBF 自适应神经模糊推理 (ANFIS)方法

基于 RBF 的 ANFIS 是通过采用神经网络来达到模糊推理的目的^[4,5],模糊控制的三个最基本的过程,即模糊化、模糊推理和反模糊化这三个过程都是通过神经网络来实现的。神经网络的自主学习机

收稿日期 2018-03-09

作者简介 王晓侃,博士生,研究方向:智能控制系统及应用, E-mail: wxkbbg@163.com

基金项目 国家留学基金委项目(20175097);河南省科技攻关计划项目(172102210124);河南省高等学校青年骨干教师培养计划项目(2016GGJS-287)

制可以对输入其中的数据进行抽取,模糊系统能够轻松表达人类的知识,还可以弥补传统的模糊控制的不足,无需反复对模糊控制器的中心函数进行调整,就可以缩减误差,提高效率。

通过学习混合算法,按照人类的认知和特定的输入/输出数据对建立起一个输入/输出映射^[6-8]。

1.1 基于 RBF 的 ANFIS 结构描述

Sugeno 模糊模型有一条非常典型的推理规则: if x is A and y is B then $z=f(x,y)$. 规则中: A 和 B 可以看做模糊数的前提, $z=f(x,y)$ 是推理结果中的精确数据, $f(x,y)$ 是 x 和 y 的多项式. 相对应的, Roger Jang 提出了一套自适应神经网络模糊推理系统,该系统可以达到学习 Sugeno 模糊模型的功能,其功能等同于一阶 Sugeno 模糊模型,可以看作是模糊模型的一种神经网络再现模式. ANFIS 的网络结构式多层前馈型的,具体如图 1 所示^[8]。

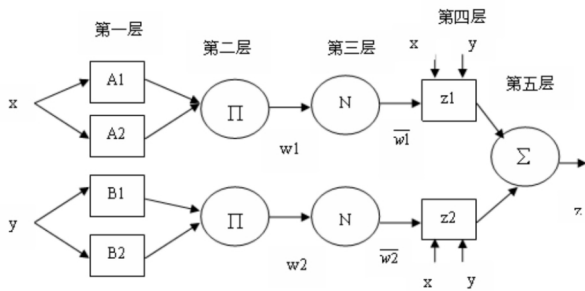


图 1 ANFIS 结构图

Fig.1 Structure of ANFIS

图中可见其输入向量为 $[x \ y]$, 权重 w_1 和 w_2 一般是在前提中的隶属函数值的乘积, f 是各种规则下输出的加权平均值, \bar{w}_1 和 \bar{w}_2 代表的是不同的权重在总权重中所占的比重. 在相同的层级节点中拥有的输出函数是一样的。

从图中给出的信息可以看出, ANFIS 模型的结构主要分为: 对模糊隶属度进行测算, 找到每一条规则的适用度, 对适用度进行规划合一, 计算每条规则的输出. 模糊系统的整体输出数据有五个层次, 数据经由输入层输送到下一个层级, 模糊化层级的输出数据是一个与模糊推理中的模糊状态相对应的隶属函数. 模糊推理层由模糊推理的前提和得出的结论两方面构成. 反模糊化层则给出一个明确的输出, 让整个系统以此执行相关任务, 通过对给定的数据样本能够灵活的调整不同层级之间的连接权系数值, 能够让系统反馈的结果更贴近实际的反应真实的系统模型. 以下是它的网络结构^[8]:

第一层是模糊化层; 主要负责对输入的数据进

行模糊化处理, 节点 i 的输出函数如下:

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

公式中的 x 代表节点 i 的输入, A_i 代表模糊集, O_i^1 则代表着 A_i 的隶属函数值, 体现了 x 属 A_i 的程度大小. 我们选择 $\mu_{A_i}(x)$ 为钟形函数, 设定它的最大值 1 或 0, 即:

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

在 (2) 式中 $\{\alpha_i, \beta_i, \gamma_i\}$ 作为前提参数, α_i 是宽度, β_i 是斜率, γ_i 是中心位置, 对这些参数进行调整, 就会让隶属函数的形状发生变化; 公式中的隶属函数可以随意分段成连续函数, 比如用梯形函数或者高斯函数等都可以。

第二层是规则的释放强度层; 该层的节点主要作用是把输入的信号进行相乘处理. 例如:

$$w_i = \mu_{A_i}(x) \times \mu_{B_i}(y) \quad i = 1, 2. \quad (3)$$

上面每一个节点的输出显示了这条规则的可信度, 任何满足 T 规范的 AND 算子都可以作为这里的“ \times ”. 这个公式项目的运算结果就明确了不同的模糊规则激活的强度。

在第三层所有的规则强度规划为一. 第 i 个节点上的第 i 条规则经过归一化处理之后的可信度计算公式如下:

$$\bar{w}_i = \frac{w_i}{w_1 + w_2} \quad i = 1, 2. \quad (4)$$

该层每个节点均为圆节点(固定节点), 计算模糊规则的权系数, 对模糊规则的激活强度。

第四层主要负责输出模糊规则. 计算不同模糊规则的输出结果数据, 公式中每一个节点都对应着一个自适应节点, 其中第 i 个节点的输出数据计算如下:

$$O_i^4 = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + \gamma_i). \quad (5)$$

这里的 \bar{w}_i 代表着第三层的输出数据, $\{p_i, q_i, \gamma_i\}$ 为分别代表不同的结论参数。

第五层是解模糊层. 在这一层立只有一个节点, 它代表的是所有的输入信号的总和, 也就是这一次推理过程得到的结论:

$$O_i^5 = \sum_i \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i}. \quad (6)$$

因此, 在给出了特定的隶属函数之后, ANFIS 最后的输出数据也就是结论可以表示为各种结论参

数的线性组合:

$$f = \frac{w_1}{w_1 + w_2} f_1 + \frac{w_2}{w_1 + w_2} f_2 = \overline{w_1} f_1 + \overline{w_2} f_2 =$$

$$(\overline{w_1 x}) p_1 + (\overline{w_1 y}) q_1 + (\overline{w_1}) \gamma_1 +$$

$$(\overline{w_2 x}) p_2 + (\overline{w_2 y}) q_2 + (\overline{w_2}) \gamma_2. \quad (7)$$

以上组合推论可得,对于拥有 m 个输入变量且每个输入变量有 k 个模糊集的 Sugeno 模糊模型,是可以上面介绍的方法来转化为神经网络结构的,这种控制规则的总数值为 $n = k^m$.

1.2 基于 RBF 的 ANFIS 学习算法

通过神经学习技术来操纵神经模拟控制器可以灵活调整神经模糊控制系统的各种参数和结构.对神经模糊控制器的调节主要有两种类型,一是结构调整,二是数据调整.对结构的调整主要包括对变量的数目、规则的数目和输入输出的变量论域划分的调整;在调整效果满意之后,就需要对参数进行相关的调整.参数的调整主要包括:与隶属函数有关的参数(中心、宽度、斜率)等进行调整.在特定的网络结构下,这种学习方法更多的是对控制器的参数进行学习和调整,即对前提参数和结论参数进行调整.

学习法主要是采用最小二乘和梯度下降结合的混合算法;这种算法综合了两种算法来辨别参数,对前提参数使用梯度下降法,对结论参数使用最小二乘法;这个学习过程包含了前向学习和反向学习两部分.前向学习主要包括了 ANFIS 的前四层学习,这四层的结论参数都是经过最小二乘算法求得的.而反向学习梯度下降法,在固定输出参数不变的前提下,通过对输入层和其他中间层的参数进行优化调整达到降低误差的目的.通过控制和掌握返回误差的变化率灵活调整前提参数 $\{\alpha_i, \beta_i, \gamma_i\}$ 优化调整隶属函数的形状,让整个样本数据的均方差数据符合规定的精准度要求.

2 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和分析负荷的历史记录数据.因此要充分考量负荷变化受到周期性影响和天气因素影响的原因及规律,找到负荷受影响及变化的规律特性.根据得出的结论应用基于 RBF 自适应神经模糊推理的方法

来预测未来的短期时间内负荷数据和走向,并应用 MATLAB 进行预测仿真^[9].

2.1 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,该模型综合分析了负荷的特点,按照日期类型分为四类:周一,工作日(周二到周五),周六,周日.每一个类型都是要全天对 24 个小时进行日负荷预测,因此四个日期类型总共建立了 96 个神经网络模型.在这个神经网络模型中我们一共设置了 96 个输入节点,每一节点采用的时间不同,分别设定在预测日一天、前两天、前一周的相同时刻;此外还包括预测日及前一天的前一个时刻和前两个时刻的负荷数据;预测日及其前一天的温度情况,包括最低温和最高温,预测日当天的天气情况数据,包括天气情况度量值和预测日当天的日期类型变量数据;96 个输入节点对应一个输出节点,也就是预测日的整点负荷值.由此可知,文中涉及到的隐含层的数目是通过实验的方法取得的;随机地对某个地区的电网进行了全天 24 小时的预测,预测数据和实际误差结果对照如下图 2 所示.

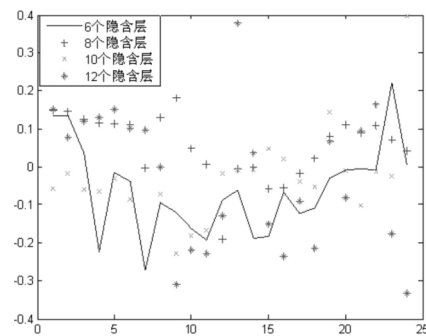


图 2 隐层神经元数目不同的预测误差曲线图

Fig.2 Hidden layer neurons in the number of different forecasting error curves

由图 2 可见,隐层神经元的数目不同,预测的结果和实际对照的误差都会不同,对比发现,当隐层神经元数为 8 时,预测结果和对照实际数据的误差平均值最小,也就是最符合实际结果.这样的实验对比结果还有很多,综合来看,当隐层神经元为 8 时,取得的预测效果最贴近实际观察结果.所以,本文确定隐层神经元数目为 8.

2.2 负荷预测方法的比较

综合采用 RBF 网络神经算法、BP 神经网络算法和基于 RBF 自适应神经模糊推理三种方法对东莞电网 2017 年 01 月 08 日的负荷数据进行预测,三种预测方法得出的结果和实际的观察负荷结果进行对比的结果如表 1 和图 3 所示.

表 1 不同预测方法的预测结果比较

Tab. 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	0.7638	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	0.0830	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	0.4480	0.0014




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

Fig.3 Bp and RBF Neural Networks Algorithm and RBF ANFIS forecasting curves

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地提高了负荷预测的精度, 达到了实际运行的需要。

从图 3 中可以看出, RBF 自适应神经模糊控制的逼近能力最好, 这表明 RBF 自适应神经模糊控制能很好地进行电力负荷的预测。

3 结语

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。

参 考 文 献

- [1] 康重庆, 夏清, 刘梅. 电力系统负荷预测 [M]. 北京: 中国电力出版社, 2007.
- [2] 肖国泉. 电力负荷预测 [M]. 北京: 中国电力出版社, 2001.
- [3] 田娜, 鞠黄培, 王旭东, 等. PCA-RBF 神经网络模型在工业用户电力负荷预测中的应用 [J]. 电器与能效管理技术, 2016(21): 58-62.
- [4] 石德琳. 基于神经网络的电力负荷预测研究与实现 [D]. 山东大学, 2016.
- [5] 聂品磊, 费东, 王宏杰, 等. 基于 EMD-BP 神经网络的短期电力负荷预测 [J]. 化工自动化及仪表, 2016, 43(3): 305-307.
- [6] 吴永峰, 蔡学志, 肖建华. 基于 RBF 神经网络的短期负荷预测方法 [J]. 自动化应用, 2017(10): 73-74.
- [7] 邵望侠, 郭卫民, 杨宁, 等. 基于 K-means 算法的 RBF 神经网络预测光伏电站短期出力 [J]. 上海电机学院学报, 2017, 20(1): 27-33.
- [8] 李文. 基于 Elman 神经网络算法的电力负荷预测模型研究 [J]. 赤峰学院学报(自然科学版), 2017, 33(21): 38-40.
- [9] 陈亚, 李萍. 基于神经网络的短期电力负荷预测仿真研究 [J]. 电气技术, 2017, 18(1): 26-29.

(责任编辑 雷建云)