

基于改进 RBF 网络算法的电力系统短期负荷预测

郭伟伟¹, 刘家学², 马云龙¹, 李书琰¹

(1. 许昌供电公司, 河南 许昌 461000; 2. 深圳供电局, 广州 深圳 518020)

摘要: 提出了一种交替梯度算法对径向基函数(RBF)神经网络的训练方法进行改进, 并将之运用于电力系统短期负荷预测。交替梯度算法通过优化输出层权值和优化 RBF 函数的中心与标准偏差值来实现。改进的算法与传统梯度下降算法相比, 具有更快的收敛速度和更高的预测精度。所构建的负荷预测模型综合考虑了气象、日类型等影响负荷变化的因素, 并在预测形式上做了巧妙处理。预测结果表明改进的 RBF 网络算法具有一定的实用性。

关键词: 短期负荷预测; 交替梯度算法; 人工神经网络; 径向基函数; 实用性

Optimal algorithm of electric power system's short-term load forecasting based on radial function neural network

GUO Wei-wei¹, LIU Jia-xue², MA Yun-long¹, LI Shu-yan¹

(1. Xuchang Power Supply Company, Xuchang 461000, China; 2. Shenzhen Power Supply Bureau, Shenzhen 518020, China)

Abstract: This paper proposes one kind of alternant gradient algorithm for improving the training of RBF neural network, which is applied to short-term electric load. This algorithm came true by optimum output layer coefficient and center and standard deviation of optimum RBF function. Compared to the traditional gradient drop algorithm, the improvement algorithm has quicker convergence rate and higher forecasting precision. The forecasting model considers many influencing factors such as weather, date-type, and so on, and deals with forecast forms very tactfully. We can see that the forecasting model has certain usability from the result of forecasting.

Key words: short-term load forecasting; alternant gradient algorithm; artificial neural network; radial basis function (RBF); usability

中图分类号: TM715 文献标识码: A 文章编号: 1674-3415(2008)23-0045-04

0 引言

短期负荷预测是电力系统运行和调度部门的一项重要工作。电力负荷的准确预测对于电力生产和电网安全运行以及国民经济都有着重要意义^[1]。但由于电力负荷变化的复杂性, 无法建立一个确定的模型来对它进行精确的预测。多年来, 国内外专家、学者对负荷预测进行了广泛深入的研究, 得出了一些有意义的结论^[1-3]。研究表明, 时间序列法(如指数平滑法、曲线拟合法等)和结构分析法(如回归法、主成分分析法等)在解决特定场合的预测任务时发挥了重要的作用。但是, 气象等不确定性因素对电力负荷的变化起着越来越重要的作用, 可是由于种种原因上述方法对这些影响因素都没能给出合理的解决途径。

负荷预测的核心问题是预测的技术方法, 或者说预测的数学模型^[4]。因而, 近年来, 以 Back Propagation 神经网络(BP)为代表的系统分析法在

负荷预测领域颇受人们青睐, 取得了比传统负荷预测更好的效果。其中, RBF 网络便是里面异军突起的一支。它强大的多元非线性映射能力使得它能够精确捕捉负荷值与气象因素等不确定因素之间的非线性关系, 大大提高了短期负荷预测的精度。本文即是针对典型的 RBF 算法, 结合电力系统短期负荷预测的实际情况, 对其训练方法加以改进, 以求网络能更快更精确地向网络目标函数收敛。并与广泛采用的传统梯度算法加以对比, 算例在收敛速度和预测精度上都表明此种改进方法有着突出的优势。

1 径向基函数的网络模型

众所周知, BP网络学习过程是一个非线性优化过程, 所以不可避免地会遇到局部极小问题, 使网络收敛速度慢或不收敛, 学习结果不理想。本文采用改进的径向基函数网络来训练样本, 该网络逼近非线性函数能力和网络收敛速度均优于BP网络。

径向基函数 RBF (Radial Basis Function) 网络

[5]与多层前向网络类似,它也是一种三层前传网络,其结构图如图1所示。在RBF网络中,输入层由信号源节点组成;第二层为隐含层,它将输入空间映射到新的空间,其单元数视所描述问题的需要而定;第三层为输出层,它对输入模式的作用做出响应。从输入空间到隐含层空间的变换是非线性的,它执行的是一种用于特征提取的非线性变换,而从隐含层空间到输出层空间变换是线性的。隐含层单元的变换函数是RBF函数,它是一种局部分布的对中心点径向对称衰减的非负非线性函数。

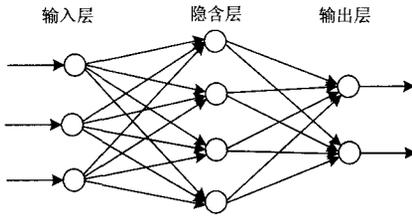


图1 RBF神经网络结构

Fig.1 The structure of radial basis function network

作为基函数的形式有很多种,但隐含层最常采用的激活函数是高斯函数。设隐含层节点数为 l 。则高斯函数为:

$$R_i(x) = \exp\left[-\frac{\|x - c_i\|^2}{2b_i^2}\right] \quad (1)$$

式中: $i=1,2,\dots,l$; x 为 n 维输入向量; c_i 和 b_i 是隐含层的两个重要参数,分别为第 i 个基函数的中心值和标准偏差值。

$R_i(x)$ 在 c_i 处有一个唯一最大值,随着 $\|x - c_i\|^2$ 的增大, $R_i(x)$ 迅速衰减到零。对于给定的输入 $x \in R^n$, 只有一小部分靠近 x 的中心被激活。

从图1可以看出,输入层实现 $x \rightarrow R_i(x)$ 的非线性映射,输出层实现 $R_i(x) \rightarrow y_k$ 的线性映射,即

$$y_k(x) = \sum_{i=1}^l w_{ki} R_i(x) \quad (2)$$

式中: $k=1,2,\dots,m$; w_{ki} 为隐含节点 i 与输出节点 k 的连接权值。

2 径向基函数网络的交替梯度算法

从函数逼近的角度看,学习的过程实际上是在 n 维的误差曲面上搜索全局最小点。 n 是训练参数的总数。对于非线性的神经网络而言,误差曲面可能存在着多个局部极小值,且随着隐节点数目的增加,

极小值点也会增加^[6]。因此,寻找或设计出好的算法,最大程度地避免陷入局部极小值是非常重要的。

2.1 交替梯度算法的理论背景

当人工神经网络的规模较大时,非线性化程度越高,传统的梯度算法训练的速度将变缓,训练的效率降低,学习速率难以精确确定,且随着学习的进行,学习系数越来越小,网络的收敛性就更加难以控制。对于短期负荷预测而言,由于要考虑多种因素的影响,网络的输入比较庞大,隐节点数目较多,非线性化的程度相对也较高,传统的梯度算法则显得有些力不从心了。为提高网络的训练效率,保证网络能够快速收敛之目的,文献[6]提到了一种采用交替梯度算法的策略。

所谓的交替梯度算法就是将网络训练分为两个阶段:输入层-隐含层阶段,隐含层-输出层阶段。训练时首先固定网络的输出层权值,运用梯度算法训练网络的中心和宽度,然后固定网络的中心和宽度,运用梯度算法训练输出层权值。这两个过程交替进行训练,直到达到要求的精度为止。

其分阶段训练示意图如图2所示。

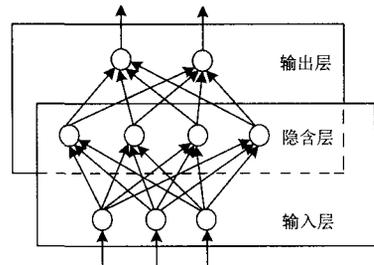


图2 两阶段训练示意图

Fig.2 Training draw of two stages

2.2 交替梯度算法的实现过程

设有训练样本集 $TS = \{x, f(x)\}$ 。网络的训练就是寻求网络参数 c_i, b_i 使得能量函数平方误差函数 $E = g(c_i, b_i, w_{ki})$, 也即

$$E = \frac{1}{2} \sum_{k=1}^m (f(x) - y_k(x))^2 \text{ 达到最小。}$$

交替梯度算法的实现分为两个阶段:优化输出层权值 w_{ki} 和优化 RBF 函数的中心与标准偏差值 c_i, b_i 。

(1) 初始化 c_i, b_i , 运用梯度算法减小 E 确定 w_{ki} :

$$w_{ki}^t = w_{ki}^{t-1} - \eta^{t-1} \frac{\partial g(c_i^{t-1}, b_i^{t-1}, w_{ki}^{t-1})}{\partial w_{ki}^{t-1}} \quad (3)$$

(2) 固定 w_{ki}^t , 运用梯度算法减小 E 确定 c_i , b_i :

$$c_i^t = c_i^{t-1} - \alpha^{t-1} \frac{\partial g(c_i^{t-1}, b_i^{t-1}, w_{ki}^t)}{\partial c_i^{t-1}} \quad (4)$$

$$b_i^t = b_i^{t-1} - \beta^{t-1} \frac{\partial g(c_i^{t-1}, b_i^{t-1}, w_{ki}^t)}{\partial b_i^{t-1}} \quad (5)$$

其中: η^{t-1} , α^{t-1} , β^{t-1} 是 $t-1$ 步的学习速率。以上两阶段交替进行, 称之为交替梯度算法。

学习速率对于网络参数的收敛非常重要, 若学习速率太小, 参数收敛特别缓慢; 学习速率过大, 参数出现振荡和发散现象。因此, 交替梯度算法根据 RBF 网络的特点, 找到新的思路和方法以提高网络中参数的精确度。使网络能快速地到达最优值附近, 从而避免了学习中不必要的振荡, 减少陷入局部极小点的可能性, 保证了网络学习的可靠性和精度。

3 基于交替梯度算法的 RBF 网络的短期负荷预测

短期负荷预测是个多变量的映射问题。电力负荷同天气、季节、日类型等诸多因素密切相关。温度的高低、日照时间的长短、季节的变迁和天气的变化都会引起负荷的幅值和曲线形状的改变。如此种种变化因素, 使得预测出精确的短期负荷一直成为电力工作者难以解决的问题。

本文即是基于前人的研究成果探索用交替梯度算法优化 RBF 神经网络算法进而进行短期负荷的预测。并以历史负荷数据和历史天气数据为训练样本, 以期寻找一个有良好泛化能力的、能进行从各种影响因素到负荷的非线性映射网络。

3.1 预测方式的确定

其实这个问题是要由预测的内容来决定的。本文是针对提前量为 1 天的日负荷进行预测建模的。预测的方式是随机的, 根据日负荷曲线的趋势我们进行采点及预测, 如果负荷分布极不均匀, 我们就按每天 24 个时刻进行预测, 如果负荷按一天的时间段分布较为均匀, 我们便把一天分为几个时间段, 把负荷数值较为接近的放在一个时段, 从而进行预测。

3.2 训练样本的选择

为保证训练样本能够覆盖整个样本空间, 更为全面地反映负荷的各种特性, 本文的训练数据选择最近的 3 个月的负荷数据和气象数据形成样本集, 且训练样本和测试样本按 8:2 比例划分。

3.3 输入变量的预处理(归一化)

输入变量选择是神经网络建模前的一项重要工作, 是否能够选出一组最能反映期望输出变化原因的输入变量, 直接关系到网络预测的性能。此外, 还要求各输入变量之间互不相关或相关性很小, 这是输入变量选择的两条基本原则。对某个变量是否适合作为网络输入没有把握, 可分别训练含有和不含有该输入的两个网络, 对其效果进行对比。

负荷预测在本质上是对未来一段时期的负荷如何受其它变量的影响进行预测, 而影响负荷变化的因素很多, 诸如前面提到的负荷、气象、日类型等量, 这些量纲不一(有些并无量纲)、数值各异, 差异甚大。为避免因输入量值域范围的较大差异而导致某些负荷影响因素在总体映射效果中的歪曲甚至淹没现象的发生, 必须对输入的有关变量进行量化处理。

另外, 神经网络在训练和学习中, 是不会直接使用原始数据的, 否则会出现神经元饱和现象, 因此必须对所有输入数据进行归一化处理。

4 算例与分析

本算例以本文所述之方法和所建之模型对某地区电网电力负荷进行了网络训练和负荷预测计算。

在网络的训练过程中, 采用交替梯度法进行网络的训练和学习。先对隐含层网络参数赋初值并固定之, 运用梯度算法按误差减小的方向确定输出层权值, 然后固定此权值再按误差减小的方向修正隐含层网络参数。如此交替进行, 直到网络误差满足要求时止。在此迭代过程中, t 步时参数 c_i^t 、 b_i^t 是由 c_i^{t-1} 、 b_i^{t-1} 、 w_{ki}^t 来确定, 而非是由 c_i^{t-1} 、 b_i^{t-1} 、 w_{ki}^{t-1} 来确定的, 这是与传统梯度算法所不同的。表 1 即为 RBF 网络分别采用交替梯度算法和传统梯度下降算法时网络的训练误差与训练时间的一览表。其中, 训练误差为平均绝对百分误差。

表 1 网络训练结果一览表

Tab.1 Data sheet of network's training results

预测时刻	交替梯度算法		传统梯度下降算法	
	训练误差 / (%)	训练时间 / s	训练误差 / (%)	训练时间 / s
时段 1	2.08	37	2.51	74
时段 2	2.39	48	2.92	92
时段 3	1.92	41	2.58	88
时段平均	2.13	—	2.67	—

从表 1 中可以看出, 交替梯度算法无论是在训练误差的统计上还是在训练时间的统计上都明显优

于传统梯度算法。从而说明了本文采用的这种优化计算具有一定的可行性。

表2 某日的整点时刻负荷预测结果

Table 2 Load forecasting results of every hour of one day

时刻	相对误差/(%)		时刻	相对误差/(%)	
	交替梯度算法	传统梯度算法		交替梯度算法	传统梯度算法
1:00	1.02	1.35	13:00	-2.13	-2.98
2:00	2.18	3.23	14:00	-2.35	-3.05
3:00	-1.59	2.88	15:00	-2.52	-3.33
4:00	1.76	2.21	16:00	0.98	-1.24
5:00	-2.38	-3.24	17:00	1.37	2.05
6:00	-3.43	1.88	18:00	2.45	2.98
7:00	1.68	2.86	19:00	2.99	3.66
8:00	3.55	4.17	20:00	1.68	2.02
9:00	3.02	4.44	21:00	1.14	-2.58
10:00	2.34	3.01	22:00	-2.65	-1.97
11:00	1.02	-2.13	23:00	-4.36	-3.54
12:00	-1.8	-1.85	0:00	-1.08	-0.85
平均绝对百分误差/(%)				2.14	2.65

表2为采用交替梯度算法的RBF网络所得到的负荷预测结果。为了能更好地说明问题,本文新的计算数据与传统梯度算法的预测结果加以对比。表中的精度计算采用相对百分误差来计量。

由表2的预测数据可以看出,交替梯度算法的预测精度要高于传统梯度算法的预测精度,在收敛速度上也有着明显的优势。传统的梯度算法是基于神经网络的短期负荷预测中广泛采用的行之有效的算法之一,与此作对比具有一定的可信度和可比性。因此通过算例可以看出,采用交替梯度算法对RBF网络算法进行改进后用于短期负荷预测具有一定的可行性和实用性。

5 结束语

对于RBF神经网络在进行短期负荷预测时,本文尝试性地提出用交替梯度算法改进传统的梯度算法,从而取得了更快的收敛速度和更高的预测精度,此种改进将有助于提高RBF网络的泛化能力,能够扩大其在短期负荷预测方面的应用前景。本文的预测实例及其分析亦表明,交替梯度算法为神经网络的训练提供了一种可行的方法,在电力系统短期负荷预测方面具有一定的实用性。

参考文献

- [1] 牛东晓,曹树华,赵磊,等. 电力负荷预测技术及其应用[M]. 北京:中国电力出版社,1998.
NIU Dong-xiao, CAO Shu-hua, ZHAO Lei, et al. The Technology of Power Load Forecasting and Its Application[M]. Beijing: China Electric Power Press, 1998.
- [2] 李鹏,任震. 广州电网负荷特性分析及短期负荷预测模型设计[J]. 电力自动化设备, 2002,22(8):50-53.
LI Peng, REN Zhen. Guangzhou Regional Load Analysis and Short Term Forecasting Model Design[J]. Electric Power Automation Equipment, 2002,22(8):50-53.
- [3] 高山,单渊达. 基于径向基函数网络的短期负荷预测[J]. 电力系统自动化, 1999,23(5):31-34.
GAO Shan, SHAN Yuan-da. A Short Term Load Forecasting Algorithm Based on Radial Basis Function Network[J]. Automation of Electric Power Systems, 1999,23(5):31-34.
- [4] 高山. 短期负荷预测的神经网络实现[J]. 电力需求侧管理, 2001,3(6):22-2.
GAO Shan. Artificial Neural Network Short-term Load Forecasting and Its Realization[J]. Power Demand Side Management, 2001,3(6):22-2.
- [5] 张涛,赵登福,周琳等. 基于RBF神经网络和专家系统的短期负荷预测方法. 西安交通大学学报, 2001,35(4): 331-334.
ZHANG Tao, ZHAO Deng-fu, ZHOU Lin, et al. Short-term Load Forecasting Using Radial Basis Function Network and Expert System[J]. Journal of Xian Jiaotong University, 2001,35(4):331-334.
- [6] 罗四维. 大规模人工神经网络理论基础[M]. 北京:清华大学出版社, 2004.
LUO Si-wei. Large-scale Artificial Neural Networks Rationale[M]. Beijing: Tsinghua University Press, 2004.

收稿日期: 2008-02-01; 修回日期: 2008-04-18

作者简介:

郭伟伟(1980-),男,硕士,工程师,主要从事电力系统负荷预测和继电保护的工作;E-mail:haifenghello@163.com

刘家学(1980-),男,硕士,工程师,主要从事电力系统规划与负荷预测的工作;

马云龙(1973-),男,本科,工程师,主要从事继电保护运行与维护工作。