

文章编号: 1002-0411(2002)03-284-05

## 基于 BP-GA 混合学习算法的神经网络短期负荷预测

杨延西 刘 丁 李 琦 郑 岗

(西安理工大学 109# 710048 Email: yangyanxi@xaut.edu.cn)

**摘要:** 本文提出了修正的遗传算法和 BP 算法相结合的短期负荷预测方法, 与传统神经网络方法相比, 该方法可以加快网络学习速度和提高学习精度. 我们用遗传算法来训练网络参数, 直到误差趋于一稳定值, 然后用优化的权值进行 BP 算法, 实现短期负荷预测. 在构建网络模型时, 我们考虑了气候因素的影响, 并把它作为网络的一组输入点. 实验结果表明基于这一方法的负荷预测系统较高的精度和实时性.\*

**关键词:** 短期负荷预测; BP; GA

中图分类号: TP13

文献标识码: B

### SHORT TERM LOAD FORECASTING USING A MULTILAYER NEURAL NETWORK WITH BP-GA MIXED ALGORITHMS

YANG Yan-xi LIU Ding LI Qi ZHENG Gang

(Xi'an University of Technology, Box 109, Xi'an 710048)

**Abstract:** In this paper, a modified method (BP-GA) for short-term load forecast is presented, which can quicken the learning speed of the network and improve the predicting precision compared with the traditional artificial neural network. We use GAs to train connection weights of multilayer feed forward neural network (BP) until the learning error has tended to stability, here, the best initial weights have been found. Then we use BP method to finish short-term load forecast process. We also consider the influence of climate for the short-term load and make it as one of the input for the BP. Experimental results show that the short-term load forecast system based on BP-GA has high precision and high learning rate.

**Keywords:** short-term load forecast, BP, GA

### 1 引言(Introduction)

电力系统负荷预测无论是对于制订电力系统规划还是实现电力系统运行自动化、安全发供电等都有着十分重要的意义. 长期以来, 国内外电力工作者对短期负荷预测理论和方法已做了大量研究, 提出了很多方法, 如常规的时间序列法和回归分析法; 属于智能原理的神经网络法、专家系统法、模糊逻辑法、模糊神经网络(NN)法、混合型方法等. 由于电力负荷变化存在着随机因素, 使时间序列和回归算法容易产生较大误差; 专家系统法需大量的知识与经验, 可维护性较差; 人工神经网络负荷预测方法是近十几年来研究和用得较多的一种方法. 由于神经网络具有并行分布信息、自学习及任意逼近连续函数的能力, 因而能捕获电力负荷的各种变化趋势, 特别是它容易处理与某些输入量如天气变量的非线性关

系. 目前用于电力系统负荷预测的神经网络主要是 BP 网络, 采用的网络权值学习算法大多是 BP(误差反向传播)算法, 网络训练费时, 并且易趋向局部最小点, 因而在实际应用特别是在线预测时受到一定的限制. 为此, 人们提出了许多改进方法, 如准则函数加惩罚项法, 启发式神经网络法以及改进的前馈网络目标模型法<sup>[2-4]</sup>等等. 但是这些方法只是侧重于网络学习性能的改善, 并没有从根本上加速网络的学习速度和提高预报精度. 本文引入遗传算法(Genetic Algorithms, 简称 GA)来训练神经网络的参数, 从而优化网络. 并把这一方法用于了某地区短期负荷预测系统中, 实验结果表明该方法加快网络学习速度, 并能提高负荷预测精度.

\* 收稿日期: 2001-09-10

## 2 BP 算法在短期负荷预测中的应用 (BP method for short-term load forecasting)

### 2.1 负荷数据预处理

电力系统负荷建模需要大量的历史数据, 而历史数据大多是通过电量采集器或远动系统采集得来, 除了受测量设备本身或者数据传输中的种种原因影响外, 还有人为拉闸限电的影响. 因此历史负荷数据中往往包含有非真实的数据, 通常称之为“不良数据”或“坏数据”, 它们或者在量级上与正常值相差很大, 或者虽然在量级上没有显著差别, 但是误差却超过了正常的范围. 如果利用这些伪数据进行负荷建模, 必然会给负荷预测带来较大的误差, 甚至导致预测算法的发散. 因此, 在利用这些数据之前, 应先对其进行预处理. 去除“不良数据”或“坏数据”的影响, 是十分必要的.

假设负荷序列用  $x(i, n)$  表示,  $i = 0, 1, \dots, 23$  表示一天中的 24 个时段,  $n = 1, 2, \dots, N$  表示取  $N$  天的负荷数据. 那么我们可以通过(1)式求出 24 个时段中每个时段  $N$  天负荷的均值  $E(i)$  及方差  $V(i)$ :

$$E(i) = \frac{1}{N} \sum_{k=1}^N x(i, k) \quad (1)$$

$$V(i) = \sigma_i^2 = \frac{1}{N} \sum_{k=1}^N [x(i, k) - E(i)]^2$$

我们定义  $\rho(i, n)$  为负荷的偏离率, 其值由下式给出:

$$\rho(i, n) = \frac{|x(i, n) - E(i)|}{\sigma_i} \quad (2)$$

因此我们可以计算出负荷的偏离率  $\rho(i, n)$ , 其中  $i = 0, 1, \dots, 23$ ,  $n = 1, 2, \dots, N$

在对负荷数据的实际处理时, 我们得到以下判据:

当  $\rho(i, n) \geq 1.1$  时, 负荷点为异常点; 当  $\rho(i, n) < 1.1$  时, 负荷点为正常点.

当负荷点为异常点时, 需要剔除. 我们利用下式的  $\bar{x}(i, n)$  来取代异常点数据  $x(i, n)$ :

$$\bar{x}(i, n) = \frac{x(i, n-1) + x(i, n+1)}{2} \quad (3)$$

利用(1)、(2)、(3)式对原始数据进行预处理后, 负荷的原序列将更加趋于合理.

### 2.2 网络输入样本的研究

利用神经网络对电力系统负荷进行预测, 实际上是利用神经网络可以以任意精度逼近任一非线性函数的特性及通过学习历史数据建模的优点. 根据负荷的历史数据, 选定前馈神经网络的输

入、输出节点, 来反映电力系统负荷运行的内在规律, 从而达到预测未来时段负荷的目的. 因此, 用神经网络对电力系统负荷进行预测, 首要的问题是确定神经网络的输入、输出节点, 能使其反映电力负荷的运行规律. 本文通过对历史负荷曲线的分析, 根据“近大远小”的原则, 确定出神经网络的历史负荷输入节点. 并对影响负荷的因素进行分析, 根据负荷的周周期性和日周期性的变化规律, 在输入节点引入“特征日”的概念.

#### 2.2.1 影响负荷因素的分析

电力系统负荷是一个很复杂的非线性系统, 有许多直接或间接的因素都会对电力系统的日负荷产生直接的影响. 但是在实际的负荷预测中, 又不能考虑太多的影响因素. 这一方面是收集这些资料困难, 另一方面因素太多会造成建模困难, 并且会带来大量的计算. 因此, 在考虑神经网络输入量的问题上, 应抓住其中几个最具特征的影响因素. 一般可把负荷分为两类[批注: 神经网络在电力系统负荷预测中的应用(欧建平)]: 周期性负荷和变动性负荷. 周期性负荷, 或者说标准负荷, 反映的是负荷自身变化的基本规律, 呈较强的周期性, 尤其受到时间周期的影响. 针对短期负荷, 时间周期因素包括: 周周期、日周期等. 它们对于日负荷的曲线模式有着极为重要的影响. 变动性负荷是随机因素影响负荷变化的结果, 一般在总负荷中所占的比重不大, 约为 10% ~ 20% 左右, 它是由于电网内偶然因素的影响造成的负荷振荡. 这种负荷, 从一个长时间周期看, 具有零平均值, 但是对于短周期而言, 负荷的振荡会使得负荷平均值有所改变. 因此对于短期负荷预测, 这种振荡的负荷是必须加以考虑的. 造成这种负荷振荡的因素主要为节假日和气象条件的影响. 在本文中把“特征日”(星期几)的归一化值作为神经网络的一个输入节点. 气象条件包括温度、湿度、风速、日照、雾障等等, 它们对负荷变化的影响一般很快, 而且无确定性的规律. 因此这就要求我们必须对变化性负荷有较大影响的气象条件加以考虑. 在气象条件中, 起主要作用的是温度因素和天气状况. 因此为了在负荷预测中考虑这两方面的影响, 本文采用了每天的最高温度、最低温度作为神经网络的两个输入量, 将天气状况模糊离散化后作为神经网络的另一组输入量<sup>[1]</sup>.

#### 2.2.2 网络输入节点的选取及网络模型

综上所述, 在网络输入节点中考虑气候影响参数, 其数学模型可用下式表示:

网络的输入矩阵为:

$$\begin{bmatrix} a_1(t-1, h) & a_1(t-2, h) & a_1(t-7, h) & T_{1H}(t) & T_{1L}(t) & m_1(t) & d_{1w}(t) \\ a_2(t-1, h) & a_2(t-2, h) & a_2(t-7, h) & T_{2H}(t) & T_{2L}(t) & m_2(t) & d_{2w}(t) \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ a_p(t-1, h) & a_p(t-2, h) & a_p(t-7, h) & T_{pH}(t) & T_{pL}(t) & m_p(t) & d_{pw}(t) \end{bmatrix}^T \quad (4)$$

网络的输出矩阵为:

$$[y_1(t) \ y_2(t) \ \dots \ y_p(t)]^T \quad (5)$$

其中  $a(t-k, h)$  为预测日  $t$  前  $k$  天  $h$  时刻的负荷值;  $y(t, h)$  为预测日  $t, h$  时刻的实际负荷;  $T_h(t)$  为预测日  $t$  的最高温度值;  $T_l(t)$  为预测日  $t$  的最低温度值;  $m(t)$  为预测日的气候敏感因素;  $d_w(t)$  为特征日系数; 其基于神经网络的算法模型结构图如图 1 所示.




图 1 基于神经网络算法的短期负荷预测系统结构图

Fig. 1 The architecture of the short-term load forecasting system based on neural network

本文中网络结构采用 7-5-1 的三层前向 BP 形式, 各层的神经元激励函数都选用 Sigmoid 函数:

$$f(u) = \frac{1}{1 + e^{-u}} \quad (6)$$

其中  $u$  为节点输入信号.

网络权值调整算法如下:

$$W_{ij}(k+1) = W_{ij}(k) + \eta e_j I_{jk}, \quad (7)$$

$$\theta_{jk}(k+1) = \theta_{jk}(k) + \eta e_j$$

其中  $I_{ij}$  为网络的节点输入信号,  $W$  为网络权值,  $\theta$  为网络的阈值,  $\eta$  为学习率,  $e_j$  为神经元节点  $j$  的误差, 当  $j$  为输出层时,

$$e_j = (O_k - \hat{O}_k) \hat{O}_k (1 - \hat{O}_k) \quad (8)$$

当  $j$  为隐层时,

$$e_j = I_{jk}(1 - I_{jk}) \sum e_n W_{ij} \quad (9)$$

其中  $O_k$  和  $\hat{O}_k$  分别为输出期望值和学习值,  $n$  为神经元节点  $j$  上一层的所有神经元. 训练目标函数为:

$$\min(E) = \min\left(\frac{1}{2} \sum_{i=1}^P (y_d - y)^2\right) \quad (10)$$

其中  $y_d$  和  $y$  分别是输出层的期望值和学习值,  $P$  为样本数.

### 3 神经网络权值训练 GA 算法 (GAs train connection weights of BP)

在 2 中采用常规 BP 网络设计方法, 设计了针对短期负荷预测的多层神经网络, 众所周知, 学习速度慢, 易陷入局部最小是这类网络的最大缺陷. 为此本文提出采用在 BP 网络训练中出现收敛速度缓慢时引入遗传算法来优化网络参数的方法, 这样可以加快网络的收敛速度, 并利用了 GA 的全局优化的优点避免 BP 的局部最小问题.

所谓网络参数的优化, 就是寻找良好的网络权值和阈值, 使得网络全局误差极小化. 遗传算法模拟了自然选择和自然遗传过程中的繁殖、交配和突变现象, 将问题的求解表示为染色体, 形成染色体群, 根据适者生存的原则, 选择优良的个体, 并对其进行复制、交叉和变异操作, 从而产生更优良的个体, 这样一代一代不断进化, 最后收敛到一个最适应环境的个体上, 求得问题最优解. 本文中采用修正的遗传算法对 BP 网络的参数进行优化, 其步骤如下:

1) 参数编码, 我们把 BP 网络的权值和阈值都作为基因, 采用实数编码方法而不用二进制编码, 这样可以缩短编码长度, 并且每个权值或阈值都单一的实数表示, 因而重组只能发生在某个权值或阈值之间有利于快速进化.

2) 初始群体的生成, 因为良好的网络权值一般比较小, 在  $(-1, 1)$  之间, 为此每个基因的取值范围为  $(-1, 1)$ . 初始群体以概率分布  $e^{-|x|}$  来随机确定, 这样使得遗传算法可以搜索所有可行解的范围.

3) 适应能力评价, 本文中适应值的计算采用下式计算:

$$\text{fitness} = \frac{1}{E} \quad (11)$$

可见  $E$  越小, 适应能力越强.

4) 用赌盘法 (Roulette Wheel) 进行选择操作.

5) 交叉和变异操作, 交叉率  $P_c$  和变异率  $P_m$  的大小对遗传的运行性能有较大的影响, 其实对于适应能力较高的解, 应取较低的  $P_c$  和  $P_m$ , 使该个体进入下一代的机会增大; 反之对于适应能力较低的解,

应取较高的  $P_c$  和  $P_m$ , 使该个体被淘汰. 本文中采用自适应交叉和变异率的操作方法如下:

$$P_c = a / (f_{max} - \bar{f}), P_m = b / (f_{max} - \bar{f}) \quad (12)$$

其中  $a$  和  $b$  是小于 1.0 的常数,  $f_{max}$  和  $\bar{f}$  分别是最大适应值和平均适应值.

6) 计算新个体的适应值, 判断是否到达终止条件, 到了则转到 7), 否则返回到 4) 继续迭代.

7) 最优个体的基因就是网络权值和阈值的最优解, 把它们用于神经网络完成负荷预测操作.

### 4 仿真实验(Simulation)

利用上述 BP-GA 混合算法模型对某地区电网负荷进行了预测. 我们取的预报日为 2000 年 4 月 17 日, 预报周为 2000 年 4 月 17~ 28 日, 以 2000 年 4 月 3~ 14 日的负荷为历史样本. 参数选择为: 编码长度为 48, 个体数为 20, 进化代数为 300,  $a = b = 0$ .

58, BP 网络学习步长为  $n = 0.01$ . 利用 MATLAB 语言进行编程实现, 我们得到的结果入图 2 和 3 所示. 图 2 为 4 月 17 日的日负荷曲线, 1 为当日实际负荷, 2 为预测负荷. 图 3 为 GAs 进化过程.

从图 2 中可以看出采用这一方法预测负荷和实际负荷非常接近, 最大相对误差为 3.42%, 平均误差为 0.92%, 完全满足电网负荷预测的要求. 而且, 采用这一方法, 网络学习速度大大提高, 多次统计平均学习次数为 5000 次, 而采用 BP 算法平均学习次数为 17000. 从图 3 中可以看出在个体进化过程到了 200 代时就找到了最优个体, 进化速度是很快的, 对应的平均适应度为 1.8034.

为进一步验证这一方法的性能, 我们又对两周的负荷进行了预测, 结果如图 4 所示. 从图中可以看出, 同样可以达到较高的预测精度.




图 2 日负荷曲线

Fig. 2 Day load-forecasting curve




图 3 GAs 进化过程

Fig. 3 GAs operating process




图 4 周负荷预测曲线

Fig. 4 Week load-forecasting curve

## 5 结论(Conclusion)

短期负荷预测对于制订电力系统规划,实现电力系统运行自动化、安全发供电等都有着十分重要的意义,前人提出了许多预测方法<sup>[3,5,6]</sup>,其中BP算法得到了广泛应用,但是BP算法存在收敛速度慢,易陷入局部最小的缺陷,本文中提出用改进GA算法对网络权值进行优化的混合算法,并把它应用于实际系统中,实验结果表明这一方法不但提高了网络学习速度,并提高了学习精度,为电力系统实现配电规划提供了有利帮助。

## 参 考 文 献 (References)

- 1 Shin-Tzo chen. Weather Sensitive Short-Term Load Forecasting Using Nonfully Connected Artificial Neural Network. Trans. On PWRs. 1992, 3: 1098~ 1105
- 2 K Y Lee. Short-Term Load Forecasting Using An Artificial Neural Network. Trans. On PWRs. 1992, 1: 124~ 131
- 3 Zhichun Mu, Ke Liu. Application of Genetic Algorithms in Identification of Linear Time-Varying System, JOURNAL OF UNIVERSITY OF SCIENCE AND TECHNOLOGY BEIJING, 2000, 7(1): 58~ 62
- 4 Ho K L, *et al.* (1992). Short Term Load Forecasting Using a Multilayer Neural Network with an Adaptive Learning Algorithm. IEEE Trans. on Power Systems, 1992, 7: 141~ 148
- 5 邹 森. 时间序列自适应短期负荷预测. 山东工业大学学报, 1988, 18(2)
- 6 欧建平, 李丽娟. 神经网络在电力系统短期负荷预测中的应用. 广东电力, 1999, 12(2)

## 作者简介

杨延西(1975- ), 男, 博士生. 研究领域为控制理论与控制工程.

刘 丁(1957- ), 男, 现为西安理工大学副校长, 教授, 博士生导师. 长期从事工业自动化、智能控制理论与应用等方面的研究, 目前承担多项国家重点科研任务, 发表论文 30 余篇, 获国家及省部级科技进步奖 4 项.

李 琦(1957- ), 男, 教授. 研究领域为工业过程检测与控制.

## 告广大作者、读者

尊敬的作者、读者:

我部自开通电子信箱投稿以来, 极大地方便了广大作者、读者. 现在网上投稿日益增多, 造成信件大量堆积. 一方面由于编辑部条件有限; 另外, 有的电子邮件带病毒, 使网络经常出现故障, 严重地影响了编辑部的正常工作. 鉴于上述原因, 今后我部决定不再接收电子信箱投稿, 作者、读者投稿一律通过邮局寄往我部.

经审查, 编辑部决定录用的稿件可以通过电子信箱发来.

望广大作者、读者周知.

《信息与控制》编辑部

《机 器 人》编辑部

2002. 4. 10