

电力系统短期负荷预测的模糊神经网络方法

姜 勇

(南京供电局,江苏 南京 210008)

摘要: 针对电力系统短期负荷预测问题,考虑气象因素对负荷的影响,提出了一种模糊神经网络的短期负荷预测方法,首先根据评价函数选取相似日学习样本,然后利用隶属函数对影响负荷的特征因素向量的分量进行模糊处理,采用反向传播算法,对24点每点建立一个预测模型,提高了学习效能。本方法适合在短期负荷预测中使用,具有较好的预测精度。

关键词: 短期负荷预测; 隶属函数; 人工神经网络

中图分类号: TM715 **文献标识码:** A **文章编号:** 1003-4897(2002)07-0011-03

1 引言

短期负荷预报是电力系统管理现代化的重要内容之一,是对发电、输电和电能分配等合理安排的必要前提,对提高电力系统的经济效益和社会效益,保障电力系统的安全经济运行与国民经济的发展具有非常重要的影响。因此,寻求有效的负荷预报方法,提高预测结果的准确度具有重要意义。

传统的预测模型是用显式的数学表达式加以描述,这就决定了它的局限性。事实上,电力负荷变化受天气情况和人们的社会活动等因素的强烈影响,存在大量非线性关系,其发展规律很难用一个显式的数学公式来表示。因此,将具备模糊数据处理能力的模糊理论与擅长拟合非线性映射的神经网络方法结合起来,是一种比较有效的预测技术。

2 模糊理论与人工神经网络方法简介^[1,2]

模糊神经网络是通过将模糊理论和人工神经网络理论有机结合起来实现的,常见的结合方式有:(1)仍采用普通神经网络的结构,但将普通非线性神经元用模糊运算神经元代替;(2)采用普通神经网络的结构和神经元作为信息处理工具,而网络的输入量、输出量等则采用输入、输出信息的模糊隶属度。本文采用的模糊神经网络为后一种类型,即将输入量经过隶属度函数转化为模糊量后,再交给神经网络进行处理,从而提高了系统的鲁棒性。

2.1 模糊集合论的概念

客观事物的差异在中介过渡时所呈现的亦此亦彼的现象称为模糊性,它体现了事物变化的连续过程。模糊集合论使用隶属度来描述中介过渡,是以精确的数学语言对模糊性的一种表述。

设论域 $u = \{x\}$, u 到闭区间 $[0, 1]$ 的任一映射 $u_A(x) : u \rightarrow [0, 1], x \rightarrow u_A(x)$ 确定了 u 的一个模糊子集,简称模糊集,记作 A ,该映射称为 A 的隶属函数。 $u_A(x)$ 的大小反映了 x 对模糊集 A 的隶属程度,简称为隶属度。实数集合上常用的隶属函数为 F 分布,主要有矩形分布,梯形分布,抛物形分布等,在实际应用中可根据对象特点加以选择。

2.2 人工神经网络和反向传播算法的原理

神经网络是由处理单元组成的一种并行、分布式信息处理结构,处理单元之间由单向信道相互连接。人工神经元是神经网络的基本计算单元,模拟了人脑中神经元的基本特征,一般是多输入/单输出的非线性单元,可以有一定的内部状态和阈值。

反向传播(Error Back Propagation—BP)算法是多层感知器的一种有效学习算法,它的模型为前向多层网络,如图1所示:

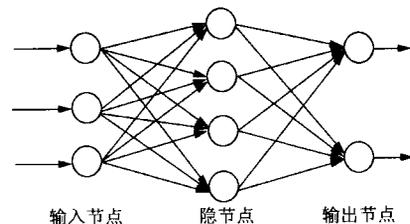


图1 BP网络

网络不仅有输入层节点,输出层节点,而且有隐含层节点,经过作用函数后,再把隐节点的输出信息传播到输出节点,最后给出结果。节点的作用函数通常选取 s 型函数,如 $f(x) = \frac{1}{1 + e^{-x}}$,这个算法的学习过程,由正向传播和反向传播组成。在正向传播过程中,输入信号从输入层经隐含层逐层处理,并传向输出层,每一层神经元的状态只影响下一层神

经元的状态。如果在输出层不能得到期望的输出,则转向反向传播,将误差信号沿原来的连接通道返回,通过修改各层神经元的权值,使得误差信号最小。

BP 算法可描述为:

(1) 权值和阈值初始化:随机给全部权值和神经元的阈值赋以较小的初始值;

(2) 给定输入 x_k 和目标输出 y_k ;

(3) 计算实际输出 \hat{y}_k (正向过程);

(4) 修正权值 (反向过程):

$$W_{ij}^{(l)} = W_{ij}^{(l)} - \frac{\partial E_k}{\partial W_{ij}^{(l)}} = W_{ij}^{(l)} - o_{ik}^{(l)} o_{jk}^{(l-1)} > 0 \quad (1)$$

式中 $W_{ij}^{(l)}$ 为第 l 层第 j 个神经元到第 $l+1$ 层的第 i 个神经元的权系数; $o_{ik}^{(l)}$ 为第 l 层 i 节点的 k 模式的误差项。且有

a. 若 i 为输出节点,则

$$o_{ik}^{(l)} = -\hat{y}_k (1 - \hat{y}_k) (y_k - \hat{y}_k) \quad (2)$$

b. 若 i 为隐节点,则

$$o_{ik}^{(l)} = o_{ik}^{(l)} [1 - o_{ik}^{(l)}] \sum_m o_{mk}^{(l+1)} W_{mi}^{(l+1)} \quad (3)$$

(5) 达到误差精度要求,则输出结果,否则回到(3)。

3 预测方法^[3]

3.1 BP 网络学习样本的选择

根据差异评价函数选择一批比较相似的负荷日,选择方法如下:

(1) 首先将影响因素向量的各分量数值化,这些因素包括日类型:工作日取 1,双休日取 2;光照:晴天取 1,少云取 2,多云取 3,阴天取 4,下雨取 5;雨量:无雨取 0,小雨取 1,中雨取 2,大雨取 3,暴雨取 4;最高温度、最低温度、平均温度等可取实际值。

(2) 建立评价函数

$$\begin{cases} \phi = - \\ = (x_1, \dots, x_k)^T \\ = (x_1, \dots, x_k)^T \end{cases} \quad (4)$$

其中 ϕ 是 ϕ 的范数, x 为已知日的影响因素向量, \hat{x} 为预测日的影响因素向量 (预测值), ϕ 为设定的偏离值,要根据不同地区的实际情况由经验决定。凡是满足该评价函数的已知日均可加入学习样本。

3.2 预测方法

为了提高 BP 网络的学习速度和鲁棒性,对网

络输出的实际负荷值进行归一化处理,同时使用隶属度函数对输入网络的影响因素向量进行模糊化处理,使得输入向量的不同分量如工作日、光照、雨量、温度等都转换为模糊量。

(1) 日类型的隶属度函数

日类型的隶属度函数采用半矩形分布。

对工作日的隶属度函数为:

$$u_{d1} = \begin{cases} 1, & \text{周 1, 2, 3, 4, 5} \\ 0, & \text{周 6, 周日} \end{cases} \quad (5)$$

对双休日的隶属度函数为:

$$u_{d2} = \begin{cases} 0, & \text{周 1, 2, 3, 4, 5} \\ 1, & \text{周 6, 周日} \end{cases} \quad (6)$$

(2) 温度的隶属度函数形式

对低温的隶属度函数采用偏小型梯形分布:

$$u_{t1} = \begin{cases} 0, & t > 10 \\ \frac{10-t}{10-0}, & 0 \leq t \leq 10 \\ 1, & t < 0 \end{cases} \quad (7)$$

对中温的隶属度函数采用中间型梯形分布:

$$u_{t2} = \begin{cases} 0, & t > 25 \text{ 或 } t < 5 \\ \frac{t-5}{15-5}, & 5 \leq t \leq 15 \\ \frac{25-t}{25-15}, & 15 < t \leq 25 \end{cases} \quad (8)$$

对高温的隶属度函数采用偏大型梯形分布:

$$u_{t3} = \begin{cases} 0, & t < 20 \\ \frac{t-20}{40-20}, & 20 \leq t \leq 40 \\ 1, & t > 40 \end{cases} \quad (9)$$

将最高温度 T_h 代入以上三个公式,可分别求出其对于低温、中温、高温三个状态的隶属度。对于最低温度 T_l 、平均温度 T_a ,可采用同样方法求出它们的三个状态隶属度。

影响因素向量的其它分量如光照、雨量等的隶属度函数与温度相似,根据当地实际情况选择建立相应的分布函数,从而求出光照的 5 个状态隶属度以及雨量的 5 个状态隶属度。

另外,为了降低求解规模,对一天的 24 点负荷每点建立一个预测模型,第 i 点的输入输出函数为:

$$L_{ji} = f_i(x_{j1}, \dots, x_{jn}) \quad (10)$$

L_{ji} 是指第 j 个学习样本第 i 点负荷的归一化值,归一化函数如下:

$$L_{ji} = \frac{L_{ji} - L_{ji \min}}{1.5L_{ji \max} - L_{ji \min}} \quad (11)$$

式中 L_{ji} 是指第 j 个学习样本第 i 点负荷的实际值; $L_{ji \min}$ 是学习样本中第 i 点负荷的最小值; $L_{ji \max}$ 是学习样本中第 i 点负荷的最大值; 经过归一化处理, $0 < L_{ji} < 1$ 。

f_i 是指第 i 点的输入输出函数, $\mu_{j1}, \dots, \mu_{jn}$ 是第 j 个样本影响因素的隶属度向量, 包括 2 个代表日类型的隶属度, 3 个代表最高温度的隶属度, 3 个代表最低温度的隶属度, 3 个代表平均温度的隶属度, 5 个代表光照的隶属度, 5 个代表雨量的隶属度。当学习完成后, 将预测日当天影响因素的隶属度向量 μ_1, \dots, μ_n 代入 (10) 式, 则可得第 i 点的负荷预测值。

3.3 注意事项

(1) 伪数据的处理

因为神经网络所用的负荷数据来自电力部门的 SCADA 系统, 由于各种原因会造成一定数量的异常数据。考虑到负荷前后小时的自然变化, 如果出现超常规值, 必须将其剔除, 代之以正常比例范围内的估计值。

(2) 待选的相似日范围

因为随着时间的推移, 系统负荷结构会发生缓慢的变化, 当已知日和预测日相隔较远时, 即使它们的天气情况等因素很相似, 预测精度也不会高, 因而取前 3 个星期的已知日作为待选范围。如果条件不能满足要求, 则可选取 3 周内 θ 最小的 2 天作为典型日学习样本。

4 计算实例分析

对南京市某日 24 点的负荷进行预测, 所得结果如表 1。

其预测的平均绝对百分误差为 2.56%, 最大预测误差为 5.1%, 最小误差为 0.1%, 误差超过 5% 的预测点有 1 个, 小于 3% 的点有 15 个, 预测效果很好。

5 结论

准确进行短期负荷预测是电力行业企盼的。本

文提出一种模糊神经网络预测方法, 利用模糊技术和神经网络各自的特长, 充分发挥了 ANN 处理非线性问题的能力, 具有训练速度快, 学习精度高, 数值稳定等优点, 算例也表明了这是一种行之有效的短期日负荷预测方法。

表 1 计算实例

时间	预测值/MW	实际值/MW	相对误差/%
0	1048.70	1026	2.2
1	994.34	979	1.6
2	967.11	972	-0.5
3	886.69	917	-3.3
4	959.98	935	2.7
5	904.23	938	-3.6
6	984.48	1025	-4.0
7	1089.31	1061	2.7
8	1169.51	1184	-1.2
9	1260.74	1259	0.1
10	1230.56	1281	-3.9
11	1307.44	1352	-3.3
12	1217.07	1181	3.1
13	1100.72	1154	-4.6
14	1234.02	1205	2.4
15	1173.74	1202	-2.4
16	1218.93	1214	0.4
17	1235.91	1265	-2.3
18	1322.47	1351	-2.1
19	1380.64	1337	3.3
20	1401.30	1425	-1.7
21	1439.53	1370	5.1
22	1227.54	1198	2.5
23	1113.06	1087	2.4

参考文献:

- [1] 杨纶标, 高英仪. 模糊数学原理及应用[M]. 广州: 华南理工大学出版社, 2001. 3.
- [2] 胡守仁, 余少波, 戴葵. 神经网络导论[M]. 长沙: 国防科技大学出版社, 1993. 10.
- [3] 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. 10.

收稿日期: 2001-11-04; 修回日期: 2002-04-28

作者简介: 姜勇(1976-), 男, 硕士, 研究方向为电力市场和电力设备故障诊断。

Fuzzy neural network for short-term load forecasting

JIANG Yong

(Nanjing Power Company, Nanjing 210008, China)

Abstract: Aiming at short-term load forecasting, this paper introduced a fuzzy ANN based on similar historical day data. This method adopted BP arithmetic and considered weather factor, selected similar historical days based on the evaluation function, deal all factors that influence load with membership function, found forecasting models for per point of 24 points, which could improve the learning property. With performing better forecasting accuracy, the method is generally suitable for short-term load forecasting.

Key words: short-term load forecasting; membership function; artificial neural network