

基于广义回归神经网络的电力系统中长期负荷预测

姚孝孝¹, 刘学琴^{1,2}, 伍利¹, 薛美娟¹

(1. 西安理工大学 电力工程系, 陕西 西安 710048;

2. 陕西理工学院 电气工程系, 陕西 汉中 723003)

摘要: 在介绍广义回归神经网络(GRNN)基本算法、网络结构及平滑参数确定方法的基础上, 提出将误差序列的均方值作为网络性能的评价指标并采用最小误差对应的平滑参数, 建立了 GRNN 的预测模型。提出了确定输入神经元数目的方法: 根据自回归模型阶次的选择经验初步确定输入神经元数目 m ; 在 m 值附近进行搜索, 对于每一个 m 值, 确定平滑参数后, 计算网络对学习样本的预测误差; 根据 BIC 准则评价指标的最小值确定输入神经元数目。将模型应用于某地中长期电力网负荷预测, 分别进行了单步预测和多步预测。与 BP 神经网络模型的预测进行比较, 结果表明, 采用该方法的预测精度明显高于 BP 模型, 即使在训练集样本数据较少时, 该方法的预测准确度仍然很高。

关键词: 广义神经网络; 中长期负荷预测; 时间序列预测; BIC 准则

中图分类号: TM 715

文献标识码: A

文章编号: 1006-6047(2007)08-0026-04

0 引言

提高负荷预测水平有利于用电管理、制定合理的电源建设规划以及提高电力系统的经济效益和社会效益^[1-2]。在中长期负荷预测中, 常采用回归模型、时间序列预测技术和灰色理论预测技术等方法^[3-4]。近年来, 随着人工神经网络研究的兴起, 先后利用神经网络进行电力系统负荷预测, 使预测误差有很大的降低, 引起负荷预测工作者的高度重视^[5]。但是, 传统神经网络是一种典型的全局逼近网络, 网络的一个或多个权值对每个输出都有影响, 导致其学习速率较慢, 加之网络在确定权值时具有随机性, 导致每次训练后输入、输出间的关系不定, 预测结果存在差异, 而且网络层数、隐含层节点数的确定缺乏理论指导^[6]。传统神经网络存在的缺点使其在实际应用中受到一定影响。而广义回归神经网络 GRNN (Generalized Regression Neural Network) 是一种局部逼近网络, 模型的建立具有明确的理论基础, 它仅需要一个简单的平滑参数, 不必进行循环的训练过程, 在训练过程中不调整神经元之间的连接权值, 网络稳健, 计算速率快^[7-12]。

现提出一种应用广义神经网络进行负荷预测的方法。用 GRNN 对我国某地区负荷进行建模并预测, 结果令人满意, 为负荷预测提供了一种可行方法。

1 广义回归神经网络 GRNN

GRNN 是由 The Lockheed Palo Alto 研究实验室的 Donald Specht 提出的一种新型的神经网络, 它

建立在数理统计的基础上, 能够根据样本数据逼近其中隐含的映射关系, 主要用于系统模型和预测。优点是学习速度快, 网络最后收敛于样本量集聚最多的优化回归面, 一旦学习样本确定, 则相应的网络结构和神经元之间的连接权值也随之确定, 网络训练过程实际上只是确定平滑参数的过程, 并且在样本数据较少时, 效果也很好, 网络可以处理不稳定的数据。人为调节的参数少, 只有一个阈值。网络的学习全部依赖数据样本。这个特点决定了网络得以最大限度地避免人为主观假定对预测结果的影响。GRNN 用标准的统计学公式计算随机变量 x 在给定测量值 X 时, 变量 y 的条件平均值 $\bar{Y}$ 。在计算这个条件平均值要用到相关可能性密度函数 (PDF), 在 GRNN 中, 相关的 PDF 使用泊松估计, 由训练矢量近似得到^[4]。

1.1 基本算法

当给定矢量随机变量 x 的一个测量值 X 时, 随机变量 y 的条件平均值为

$$\bar{Y}(X) = \int_{-\infty}^{\infty} y f\left(\frac{X}{y}\right) dy / \int_{-\infty}^{\infty} f\left(\frac{X}{y}\right) dy \quad (1)$$

在此, $f(X/y)$ 是 y 和 x 的相关可能性密度函数。

在 GRNN 中, $f(X/y)$ 用泊松近似, 其窗口为常对角协方差矩阵。

$$\hat{f}(X/y) = \frac{1.0}{(2\pi\sigma^2)^{(N+1)/2}} \times \frac{1}{T} \times \sum_{i=1}^T \left\{ \exp\left(\frac{-D_i^2}{2\sigma^2}\right) \exp\left[\frac{-(y-Y^{(i)})^2}{2\sigma^2}\right] \right\} \quad (2)$$

式中 $\{(X^{(t)}, Y^{(t)}), t=1, \dots, T\}$ 是一组输入、输出值, 且有

$$D_i = |x - X^{(i)}| = \sqrt{\sum_{j=1}^N (x_j - X_j^{(i)})^2} \quad (3)$$

D_i 为 $\mathbf{x}$ 和 $\mathbf{X}^{(i)}$ 之间的欧几里德距离, N 是输入空间的维数,即在网络中的输入单元数。

σ 是一个宽度函数,当泊松窗口的数量 T 变化大时,必须满足下列趋势。

$$\lim_{T \rightarrow \infty} \sigma(T) = 0, \quad \lim_{T \rightarrow \infty} (T\sigma^N(T)) = 0$$

将 PDF 的估计方程式(2)直接代入式(1),改变积分分和顺序,可得到下面的条件平均估计:

$$\bar{Y}(\mathbf{X}) = \frac{\sum_{i=1}^T \left[\exp\left(-\frac{D_i^2}{2\sigma^2}\right) \right] \int_{-\infty}^{\infty} \mathbf{y} \exp\left[-\frac{(\mathbf{y}-\mathbf{Y}^{(i)})^2}{2\sigma^2}\right] d\mathbf{y}}{\sum_{i=1}^T \left[\exp\left(-\frac{D_i^2}{2\sigma^2}\right) \right] \int_{-\infty}^{\infty} \exp\left[-\frac{(\mathbf{y}-\mathbf{Y}^{(i)})^2}{2\sigma^2}\right] d\mathbf{y}} \quad (4)$$

若设变量 $\mathbf{z} = \mathbf{y} - \mathbf{Y}^{(i)}$,分子的积分项可化简为

$$\int_{-\infty}^{\infty} \mathbf{y} \exp\left[-\frac{(\mathbf{y}-\mathbf{Y}^{(i)})^2}{2\sigma^2}\right] d\mathbf{y} = \int_{-\infty}^{\infty} (\mathbf{z} + \mathbf{Y}^{(i)}) \times \exp\left(-\frac{\mathbf{z}^2}{2\sigma^2}\right) d\mathbf{z} = \mathbf{Y}^{(i)} \int_{-\infty}^{\infty} \exp\left(-\frac{\mathbf{z}^2}{2\sigma^2}\right) d\mathbf{z} \quad (5)$$

分母中的积分项化简为

$$\int_{-\infty}^{\infty} \exp\left[-\frac{(\mathbf{y}-\mathbf{Y}^{(i)})^2}{2\sigma^2}\right] d\mathbf{y} = \int_{-\infty}^{\infty} \exp\left(-\frac{\mathbf{z}^2}{2\sigma^2}\right) d\mathbf{z} \quad (6)$$

将式(5)(6)代入式(4),可得:

$$\bar{Y}(\mathbf{X}) = \frac{\sum_{i=1}^T \left[\exp\left(-\frac{D_i^2}{2\sigma^2}\right) \mathbf{Y}^{(i)} \int_{-\infty}^{\infty} \exp\left(-\frac{\mathbf{z}^2}{2\sigma^2}\right) d\mathbf{z} \right]}{\sum_{i=1}^T \left[\exp\left(-\frac{D_i^2}{2\sigma^2}\right) \int_{-\infty}^{\infty} \exp\left(-\frac{\mathbf{z}^2}{2\sigma^2}\right) d\mathbf{z} \right]} = \frac{\sum_{i=1}^T \left[\mathbf{Y}^{(i)} \exp\left(-\frac{D_i^2}{2\sigma^2}\right) \right]}{\sum_{i=1}^T \exp\left(-\frac{D_i^2}{2\sigma^2}\right)} \quad (7)$$

1.2 网络结构

GRNN 结构如图 1 所示,包括输入层、模式层、求和层与输出层 4 层神经元。对应网络输入 $\mathbf{X} = [x_1, x_2, \dots, x_m]^T$,其输出为 $\mathbf{Y} = [y_1, y_2, \dots, y_l]^T$ 。




图 1 广义回归神经网络模型

Fig.1 The model of GRNN

输入层的神经元数目等于学习样本中输入层的维数 m ,各神经元是简单的分布单元,直接将输入变量传递给隐层。

模式层的神经元数目等于学习样本数目 n ,各神经元对应不同样本,其神经元 i 的传递函数为

$$P_i = \exp[(\mathbf{X} - \mathbf{X}_i)^T(\mathbf{X} - \mathbf{X}_i)/(2\sigma^2)] \quad i=1,2,\dots,n \quad (8)$$

其中, $\mathbf{X}$ 为网络输入变量, $\mathbf{X}_i$ 为神经元 i 对应的学习样本, σ 为平滑参数,即神经元 i 的输出为输入变量 $\mathbf{X}$ 与其对应样本 $\mathbf{X}_i$ 间的 Euclid 距离平方的指数形式:

$$D^2 = (\mathbf{X} - \mathbf{X}_i)^T(\mathbf{X} - \mathbf{X}_i) \quad (9)$$

求和层包括 2 种类型神经元,其中一种神经元对

所有模式层神经元的输出进行算术求和,模式层各神经元与该神经元的连接权值为 1,传递函数为

$$S_D = \sum_{i=1}^n P_i \quad i=1,2,\dots,L \quad (10)$$

其他神经元对所有模式层神经元的输出进行加权求和,模式层中第 i 个神经元与求和层中第 j 个求和神经元之间的连接权值为第 i 个输出样本 $\mathbf{Y}_i$ 中的第 j 个元素 y_{ij} ,求和神经元的传递函数为

$$S_{Nj} = \sum_{i=1}^n y_{ij} P_i \quad j=1,2,\dots,L \quad (11)$$

输出层中的神经元数目等于学习样本中输出向量的维数 L ,各神经元将求和层的输出相除,即

$$y_i = S_{Nj} / S_D \quad j=1,2,\dots,L \quad (12)$$

1.3 平滑参数确定

对于 GRNN,学习样本确定,则相应的网络结构和各神经元之间的连接权值也随之确定,网络的训练实际上只是确定平滑参数的过程。与传统的误差反向传统算法不同,GRNN 的学习算法在训练过程中不调整神经元之间的连接权值,而是改变平滑参数,从而调整模式层中各单元的传递函数,以获得最佳的回归估计结果。对于时间序列预测问题,由于样本是具有相同属性的观测值,因此这里 GRNN 的平滑参数取为相同的值。平滑参数对广义神经网络的预测性能影响较大。考察式(4),若平滑参数较大,则概率密度函数的估计比较平滑,为多元 Gauss 函数,协方差矩阵为 $\sigma^2 \mathbf{I}$,当平滑参数 $\sigma \rightarrow \infty$ 时,估计值 $\hat{\mathbf{Y}}(\mathbf{X})$ 为所有样本观测值 $\mathbf{Y}_i$ 的均值;若平滑参数较小,则概率密度函数的估计为非 Gauss 型,当平滑参数 $\sigma \rightarrow 0$ 时,估计值 $\hat{\mathbf{Y}}(\mathbf{X})$ 为与输入变量 $\mathbf{X}$ 之间 Euclid 距离最近的样本观测值;对于适中的平滑参数,所有样本观测值均计算在内。其中,与 $\mathbf{X}$ 之间 Euclid 距离较近的样本观测值的权重因子较大。

为获得理想回归估计结果,提出了平滑参数的确定方法:令平滑参数以增量 $\Delta\sigma$ 在一定范围 $[\sigma_{\min}, \sigma_{\max}]$ 内递增变化;在学习样本中,除去一个样本,用剩余的样本构造 GRNN 对该样本进行估计,得到估计值与样本值之间的误差,对每一样本重复该过程,得到误差序列,其均方值为

$$E = \frac{1}{n} \sum_{i=1}^n [\hat{\mathbf{Y}}_i(\mathbf{X}_i) - \mathbf{Y}_i]^2 \quad (13)$$

将误差序列的均方值作为网络性能的评价指标,将最小误差对应的平滑参数用于最后的 GRNN。在确定平滑参数的过程中,初始值 $\sigma_{\min}$ 太小,式(4)可能会出现除以 0 的情况,给出如下 $\sigma_{\min}$ 的计算方法:

$$\sigma_{\min} = [-D_{\min}^2 / (2 \ln \varepsilon)]^{1/2}$$

式中 $D_{\min}$ 为学习样本中各输入样本间 Euclid 距离的最小值; $\varepsilon > 0$ 为计算机可表达的最小正数。

平滑参数的确定过程隐含了网络性能的验证过程。因此,网络学习样本中无需另外的验证数据。

2 时间序列的中长期负荷预测过程

2.1 时间序列预测

时间序列预测为一种由历史记录计算未来趋势的数学映射,通过 m 点历史数据对未来趋势进行提前 l 步预测的数学模型为

$$(x(i), x(i+1), \dots, x(i+l)) = p(x(i-1), x(i-2), \dots, x(i-m))$$

$$i = m+1, m+2, \dots, m+(N-m-l)/s$$

式中 $(N-m-l)/s$ 为子学习样本数目; N 为样本数据长度; s 为滑动点数(一般取为 1)。

由于 GRNN 能够逼近样本数据中隐含的映射关系,因此可以用其解决时间序列预测问题。

2.2 输入神经元数目的确定

应用 GRNN 进行时间序列预测时,如何选择输入神经元数目(即输入样本长度,对应式(4)中样本 X_i 的维数)是一个重要问题。在样本数据已知的情况下,输入神经元的数目过大,则供网络训练的子学习样本太少,反之,输入神经元的数目过小,则子学习样本太多。由于网络的输出结果是子学习样本对应的样本观测值的加权平均,故输入神经元数目对 GRNN 的预测性能存在影响。

关于输入神经元数目的确定问题,目前还没有理论计算公式。笔者参考自回归(AR)模型阶次的选择方法,提出了确定输入神经元数目的方法。

首先,根据自回归模型阶次的选择经验,初步确定输入神经元数目:

$$m = \begin{cases} N/2 & N=20 \sim 40 \\ N/3 \sim N/2 & N=40 \sim 100 \\ N/\ln N & N=100 \sim 200 \end{cases}$$

然后,在 m 值附近进行搜索,对于每一个 m 值,确定平滑参数之后,由式(5)计算网络对学习样本的预测误差 E 。

最后,根据 BIC 准则评价指标 $BIC(m) = N \ln E + m \ln N$ 的最小值确定输入神经元数目。实际应用中,可以将网络对学习样本的预测误差 E 作为评价指标,当满足一定的精度要求时,即可以终止搜索过程。

2.3 中长期负荷的时间序列预测

分别应用 GRNN 和传统的采用误差反向传播算法的 3 层前馈感知器网络(BP 神经网络)对我国某省年负荷时间序列进行预测,并对比了预测性能。

2.3.1 未来 1 年的负荷预测

将前 36 年的历史数据作为学习样本,后 6 年的数据作为测试样本,滑动点数为 1。GRNN 对学习样本的预测误差均方值与 BIC 评价指标值相对于输入神经元数目的变化情况分别如图 2 和图 3 所示。根据最小的 BIC 值确定输入神经元数目为 13,得到子学习样本 16 个,确定最优平滑参数为 0.126。

GRNN 和 BP 神经网络的预测结果如表 1 和图 4 所示(曲线 1、2、3 分别为历史负荷、GRNN 预测结果、BP 预测结果, W 为用电量, a 为年份,后同)。可见,2 种网络均预测出了 1980 年到 1985 年的负荷数据,




图 2 输入神经元数目和预测误差

Fig.2 The input neuron numbers and corresponding forecast errors




图 3 BIC 值和输入神经元数目

Fig.3 The BIC index vs. input neuron number

表 1 单步预测结果

Tab.1 Single-step forecast result

神经网络	结构	平滑参数	样本 MSE	
			训练	测试
BP	13-10-1	-	0.01445	0.01366
GRNN	13-16-2-1	0.126	0.00556	0.00447

注: MSE 为均方误差,后同。




图 4 几种预测结果的比较

Fig.4 Comparison of different forecast methods

但是,与 GRNN 相比,BP 网络预测结果的误差较大。

2.3.2 未来 4 年的负荷预测

对未来 4 年的负荷做预测,将前 32 年的数据作为学习样本,后 4 年数据作为测试样本,滑动点数为 1,按照前述方法确定输入神经元数目为 15,得到 13 个子学习样本,确定最优平滑参数为 0.155。GRNN 和 BP 神经网络的预测结果如表 2 和图 5 所示。可见,GRNN 较 BP 网络的预测结果准确。

表 2 未来 4 年的负荷预测

Tab.2 Load forecasts of the following four years

神经网络	结构	平滑参数	样本 MSE	
			训练	测试
BP	15-10-4	-	0.00785	0.00653
GRNN	15-13-5-4	0.155	0.00352	0.00432




图 5 几种预测结果的比较

Fig.5 Comparison of different forecast methods

3 结论

分别采用传统的 BP 网络和 GRNN 网络对我国某地中长期负荷进行预测,通过对预测结果分析表明 GRNN 预测精度明显优于 BP 网络。其原因之一是

来自于训练样本的影响;传统的神经网络是一种典型的全局逼近网络,要求训练样本能包含该类事物所具有的全部或大部分特征,因此训练集必须有一定的数量、质量,且样本必须能概括这类事物的全部特征(也即样本必须具有一定的代表性),网络才有可能具有较好的预测效果。另一方面是来自于网络结构的影响:传统的网络是一种多层前向网络,初始权值一般随机赋值,训练循环进行,通过不断调整各连接权之间的权值达到最终构建网络的目的。因此,网络的一个或多个权值对每个输出都有影响,每次随机赋值都会得到不同的预测结果,致使网络不够稳健。而循环训练会导致学习速率降低,学习时间冗长。加之网络结构的构建没有成熟的理论支持,具有一定的盲目性,最终预测结果会有较大的误差。而 GRNN 建立在数理统计基础上,具有明确的理论依据,根据文中提出的方法选取输入神经元的数目后,学习样本确定,网络结构和连接权值也随之确定,而且在训练过程中不涉及随机数,只需要确定平滑参数一个变量。因此,相对于 BP 神经网络而言,GRNN 更适合于解决具有时间序列的负荷预测问题。通过对我国某省中长期的负荷预测,结果表明是可行的。

参考文献:

- [1] 刘晨晖. 电力系统负荷预报理论与方法[M]. 哈尔滨:哈尔滨工业大学出版社,1987.
- [2] 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.
- [3] 游仕洪,程浩忠,谢宏. 应用模糊线性回归模型预测中长期电力负荷[J]. 电力自动化设备,2006,26(3):51-53.
YOU Shi-hong, CHENG Hao-zhong, XIE Hong. Mid- and long-term load forecast based on fuzzy linear regression model[J]. Electric Power Automation Equipment, 2006, 26(3): 51-53.
- [4] 顾洁,申刚,许光虎. 改进的电力系统中长期负荷预测方法研究[J]. 电力自动化设备,2002,22(6):1-4.
GU Jie, SHEN Gang, XU Guang-hu. Study on improved method for mid- and long-term load forecasting of power system[J]. Electric Power Automation Equipment, 2002, 22(6): 1-4.
- [5] 张国忠,熊伟,向求新,等. 应用人工神经网络预测电力负荷[J]. 电力自动化设备,2002,22(5):20-21.
ZHANG Guo-zhong, XIONG Wei, XIANG Qiu-xin, et al. Power load forecast using artificial neural network[J]. Electric Power Automation Equipment, 2002, 22(5): 20-21.
- [6] 张立明. 人工神经网络的模型及其应用[M]. 上海:复旦大学出版社,1993.
- [7] 张际先,宓霞. 神经网络及其在工程中的应用[M]. 北京:机械工业出版社,1996.
- [8] 冯志鹏,宋希庚,薛冬新,等. 基于广义回归神经网络的时间序列预测研究[J]. 振动、测试与诊断,2003,23(2):105-109.
FENG Zhi-peng, SONG Xi-geng, XUE Dong-xin, et al. General regression neural network based prediction of time series[J]. Journal of Vibration, Measurement & Diagnosis, 2003, 23(2): 105-109.
- [9] 何琴,高建华,刘伟. 广义回归神经网络在烤烟内在质量分析中的应用[J]. 安徽农业大学学报,2005,32(3):406-410.
HE Qin, GAO Jian-hua, LIU Wei. Application of generalized regression neural network into internal quality evaluation of flue-cured tobaccos[J]. Journal of Anhui Agricultural University, 2005, 32(3): 406-410.
- [10] 谷志红,牛东晓,王会青. 广义回归神经网络模型在短期电力负荷预测中的应用研究[J]. 中国电力,2006,39(4):11-14.
GU Zhi-hong, NIU Dong-xiao, WANG Hui-qing. Research on application of general regression neural network in short-time load forecasting[J]. Electric Power, 2006, 39(4): 11-14.
- [11] SPECHT D F. A general regression neural network[J]. IEE Transactions on Neural Networks, 1991, 2(6): 568-576.
- [12] CHTIIOU Y, PANIGRAHI S, FRANCL L. A generalized regression neural network and its application for leaf wetness prediction to forecast plant disease[J]. Chemometrics and Intelligent Laboratory Systems, 1999, 48(1): 47-58.

(责任编辑:李育燕)

作者简介:

姚李孝(1962-),男,陕西蒲城人,教授,研究方向为电力系统自动化(E-mail: YLX@xaut.edu.cn);

刘学琴(1973-),女,陕西汉中,讲师,硕士,研究方向为电力系统自动化(E-mail: liu2291292@126.com);

伍利(1970-),女,陕西蓝田人,讲师,硕士,研究方向为电力系统自动化。

Mid- & long-term load forecast based on GRNN

YAO Li-xiao¹, LIU Xue-qin^{1,2}, WU Li¹, XUE Mei-juan¹

(1. Department of Electrical Engineering, Xi'an University of Technology, Xi'an 710048, China;

2. Department of Electrical Engineering, Shaanxi University of Technology, Hanzhong 723003, China)

Abstract: The basic arithmetic and network structure of GRNN (Generalized Regression Neural Network), as well as the determination of smoothing parameter, are introduced, based on which, a forecast model of GRNN is established by taking the mean square error of error series as the evaluation criterion and adopting the smoothing parameter with minimal error. The method to decide the input neuron number is proposed: it is initialized to m by experience according to the order of self-regression model; the smoothing parameters for different input neuron numbers around m are used to calculate the corresponding forecast errors of training samples; the final input neuron number is decided according to the minimal evaluation index of BIC rule. The GRNN is applied to single-step and multi-step mid- & long-term load prediction. Compared with BP network, the presented method has higher forecast precision, even for sparse training samples.

Key words: GRNN; mid- & long-term load forecast; time series prediction; BIC rule