

基于 GM-GRNN 的电力系统长期负荷预测

吴耀华

(陕西理工学院电气工程系, 陕西 汉中 723003)

摘要: 由于长期负荷历史数据比较少, 因此预测难度较大。在分析了灰色预测和神经网络预测的优缺点的基础上, 提出了一种新型的预测方法——GM-GRNN 预测方法, 此方法就是将灰色预测方法和人工神经网络中的广义神经网络相结合的预测方法, 新方法发挥了灰色预测方法中的“累加生成”的优点, 能够削弱原始数据中随机性并增加规律性, 同时避免了灰色预测方法及其预测模型存在的理论误差。最后采用我国某省年用电量的预测的算例表明该方法的预测精度优于单一的灰色预测和单一的神经网络预测方法, 为电力系统长期负荷预测提供了一种有用的方法。

关键词: 电力系统; 长期负荷预测; 人工神经网络; 广义人工神经网络; 灰色预测

Long term load forecasting based on GM-GRNN in power system

WU Yao-hua

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

Abstract: Because of lack of history load data, it is more difficult to predict long time load. The paper analyzes the merits as well as defects of grey prediction method and artificial neural network (ANN) method, and proposes a novel forecasting method named grey neural network. The new method utilizes the accumulation generation operation of grey prediction to transform original data and produce accumulated data. The data possesses better regularity which makes it easier to model and train the ANN and avoid the theoretical error of grey prediction method. Case study shows that this method is more accurate and faster than single grey prediction and single neural network method. It is a useful method for long term load forecasting.

Key words: power system; long term load forecasting; artificial neural network; generalized regression neural network; grey prediction

中图分类号: TM715

文献标识码: A

文章编号: 1003-4897(2007)06-0045-04

0 引言

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。此外, 从发展来看, 负荷预测也是我国实现电力市场的必备条件。常用的负荷预测方法有外推法、相关分析法和时间序列法等, 近年来有很多学者通过引入人工神经网络、灰色系统、小波和混沌等理论来探讨新的预测方法^[1, 2]。灰色预测方法通过累加生成来削弱随机干扰的影响, 比较适合预测电力负荷变化的总体趋势, 因此通常用于中长期电力负荷预测。但是, 灰色预测方法理论上只适合预测呈近似指数增长规律的数据序列, 而且求解参数 a 和 u 的算法也有一定的问题^[3]。人工神经网络已经被证明适合解决电力负荷预测问题, 尤其在短期

负荷预测中得到重视和应用。基于神经网络的方法具有传统建模方法所不具备的诸多优点: 如对被建模对象的先验知识要求不多, 一般不必事先对多个对应数据之间进行数学建模, 只需给出对象的输入, 输出数据, 通过网络本身的学习功能就可以掌握不易明确表达的知识和经验并达到输入与输出的完全符合等优点。但是, 传统的神经网络也有很多不足之处: 它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, 导致每次训练之后输入输出之间的关系不定, 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^[4]。

由于传统神经网络存在这些缺点, 使其在实际应用中受到一定的影响。因此, 本文提出了一种结

合灰色模型和广义神经网络进行负荷预测的方法。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, GRNN 不同于传统的神经网络, 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^[5-8]。本文提出的结合灰色模型和广义神经网络的模型预测方法既发挥了灰色预测方法中累加生成的优点, 便于神经网络进行训练, 又避免了灰色预测方法带来的理论误差^[9, 10]。最后的算例表明本文方法用于长期负荷预测时, 预测精度优于单一的广义人工神经网络或者灰色预测方法。

1 GM(1, 1) 和 GRNN 模型简介

1.1 GM(1, 1) 模型简介

灰色理论是将无规律的原始数据经生成后, 使其变为较有规律的生成数列再建模, 所以 GM 模型实际上是生成数列模型, 一般用微分方程描述, 由于 GM 模型的解是微分方程的解, 是指数曲线, 因此要求生成数列是递增的且接近指数曲线, 电力系统负荷本身均为正值, 经一次累加生成后即变为递增数列。

1) 设给定原始序列, 并记为:

$$x^{(0)} = [x^{(0)}(1), x^{(0)}(2), \dots, x^{(0)}(n)];$$

2) 对数列作一次累加生成新的序列

$$x^{(1)} = [x^{(1)}(1), x^{(1)}(2), \dots, x^{(1)}(n)];$$

其中: $x^{(1)}(t) = \sum_{n=1}^t x^{(0)}(n) \quad t = 1, 2, \dots, n$

3) 构造累加矩阵与常数项向量 y_n

$$y_n = [x^{(0)}(2), x^{(0)}(3), \dots, x^{(0)}(N)]^T$$

建立相应的微分方程模型为 $\frac{dx^{(1)}}{dt} + ax^{(1)} = u$

式中: a, u 是参数, u 称为控制项。

$$B = \begin{bmatrix} -\frac{1}{2}[x^{(1)}(1) + x^{(1)}(2)] & 1 \\ -\frac{1}{2}[x^{(1)}(2) + x^{(1)}(3)] & 1 \\ \vdots & \vdots \\ -\frac{1}{2}[x^{(1)}(n-1) + x^{(1)}(n)] & 1 \end{bmatrix}$$

4) 用最小二乘法求解灰参数

$$\begin{bmatrix} \hat{a} \\ \hat{u} \end{bmatrix} = (B^T B)^{-1} B^T y_n$$

5) 该微分方程的解为

$$x^{(1)}(t+1) = [x^{(0)}(1) - \frac{\hat{u}}{\hat{a}}]e^{-\hat{a}t} + \frac{\hat{u}}{\hat{a}}$$

6) 累减还原得到

$$x^{(0)}(t+1) = x^{(1)}(t+1) - x^{(1)}(t) = (1 - e^{-\hat{a}})[x^{(0)}(1) - \frac{\hat{u}}{\hat{a}}]e^{-\hat{a}t} \quad t = 1, 2, \dots$$

1.2 GRNN 广义回归神经网络模型简介

GRNN 网络是由 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隐射关系, 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, 并且在样本数据较稀少时, 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来计算在随机变量 x 的给定测量值 X 时, 变量 y 的有条件平均值 Y 。在计算这个条件平均值是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, 由训练矢量近似来得到。

1.2.1 广义神经网络的基本算法

当给定矢量随机变量 x 的一个测量值 X 时, 随机变量 Y 的条件平均为

$$\bar{Y}(X) = \frac{\int y f(X/y) dy}{\int f(X/y) dy} \quad (1)$$

在此 $f(X/y)$ 是 y 和 x 的相关可能性密度函数。

在 GRNN 中, $f(X/y)$ 用泊松来近似, 其窗口为常对角斜方差矩阵。

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

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

$$D_t = |x - X^{(t)}| = \sqrt{\sum_{i=1}^N (x_i - X_i^{(t)})^2} \quad (3)$$

为 x 和 $X^{(t)}$ 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, 必须满足下列的趋势。

$$\lim_{T \rightarrow \infty} \sigma(T) = 0$$

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

将 pdf 的估计方程 (2) 直接带入 (1), 改变积分求和顺序, 可得到下面的条件平均估计。

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

若设变量 $z = y - Y^{(i)}$, 分子的积分项可化简为

$$\int_{-\infty}^{\infty} y \exp[-\frac{(y-Y^{(i)})^2}{2\sigma^2}] dy = \int_{-\infty}^{\infty} (z + Y^{(i)}) \exp(-\frac{z^2}{2\sigma^2}) dz = Y^{(i)} \int_{-\infty}^{\infty} \exp(-\frac{z^2}{2\sigma^2}) dz \quad (5)$$

分母中的积分项化简为

$$\int_{-\infty}^{\infty} \exp[-\frac{(y-Y^{(i)})^2}{2\sigma^2}] dy = \int_{-\infty}^{\infty} \exp(-\frac{z^2}{2\sigma^2}) dz \quad (6)$$

将式 (5)、式 (6) 代入式 (4), 可得到

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

1.2.2 广义神经网络的结构

GRNN 结构如图 1 所示, 包括输入层, 模式层, 求和层与输出层四层神经元。对应网络输入 $X = [x_1, x_2, \dots, x_m]^T$, 其输出为 $Y = [y_1, y_2, \dots, y_l]^T$ 。

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含层。

模式层的神经元数目等于学习样本的数目 n , 各神经元对应不同的样本, 模式层中神经元 i 的传递函数为

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

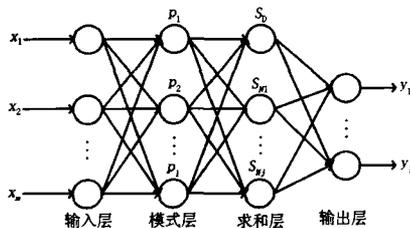


图 1 广义回归神经网络模型

Fig.1 Generalized regression neural network

其中, X 为网络输入变量, Xi 为神经元 i 对应的学习样本, σ 为平滑参数, 也就是说, 神经元 i 的输出为输入变量 X 与其对应的样本 Xi 之间的 Euclid 距离平方的指数形式

$$D^2 = (X - Xi)^T (X - Xi) \quad (9)$$

求和层包括两种类型神经元, 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 Y_i 中的第 j 个元素 y_{ij} , 求和神经元的传递函数为

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

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

$$y_j = \frac{S_{N_j}}{S_D}, \quad j = 1, 2, \dots, L \quad (12)$$

1.3 GM 与 GRNN 方法的互补性

虽然 GRNN 和 GM 预测方法存在较大差异, 但是根据它们各自的特点, 又存在以下互补性:

1) 灰色预测方法理论上只适合预测呈近似指数增长规律的数据序列, 而且求解参数 a 和 u 的算法有一些缺陷。人工神经网络已经被证明适合解决电力负荷预测问题, 因此两者有结合的必要性。

2) 在中长期负荷预测中, 样本的数量相对较少, 灰色预测方法则能够利用少样本进行建模和预测, 而 GRNN 在样本数据稀少的情况下, 也可以达到一定的预测精度。所以两者有结合的可能。

3) 灰色预测方法的累加生成不但能够削弱随机干扰的影响, 而且累加后的序列呈单调增长, 比较适合用 GRNN 神经网络进行逼近。

因此, 将 GRNN 和 GM 预测方法结合起来, 使它们互相取长补短, 构造性能更好的负荷预测方法是可行的。

2 预测实例及结果

2.1 时间序列的长期负荷预测过程

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

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

其中: $(N - m - l) / s$ 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)。由于广义回归神经网络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 串联 GM-GRNN 及其算法

根据以上对 GRNN 神经网络和灰色预测方法特点的分析, 本文提出只保留灰色预测方法中的“累加生成”和“累减还原”运算, 不再求参数 a 和 u , 而是由 GRNN 神经网络来建立预测模型和求解模型参数。利用 GM-GRNN 神经网络进行电力负荷预测的算法如下:

电力负荷的原始数据序列进行“累加生成”运算, 得到累加序列。这样可以削弱原始数据中存在的随机性, 突出总体发展趋势。

1) 电力负荷的原始数据序列为:

$x^{(0)} = [x^{(0)}(1), x^{(0)}(2), \dots, x^{(0)}(n)]$, 共有 n 个数据。按照灰色累加生成, 得到累加序列:

$$x^{(1)} = [x^{(1)}(1), x^{(1)}(2), \dots, x^{(1)}(n)],$$

其中: $x^{(1)}(t) = \sum_{n=1}^t x^{(0)}(n) \quad t=1, 2, \dots, n$

2) 利用 GRNN 对生成序列 $x^{(1)}$ 进行训练。

3) 利用训练好的 GRNN 神经网络进行预测, 输出累加序列的预测值

4) 将累加数据的预测值进行“累减还原”运算, 得到电力负荷的原始数据序列的预测值。

2.3 算例分析

本例对我国某省的年负荷时间序列进行了预测, 共有 36 年的历史数据, 1950-1985 年的负荷数据, 首先利用灰色累加生成序列

$$x^{(1)} = [x^{(1)}(1), x^{(1)}(2), \dots, x^{(1)}(36)]$$

表 1 三种方法预测的绝对误差

Tab.1 Comparison of forecasting errors with three methods

年份	GRNN	GM	本文方法
1980	-4.544	5.678	3.221
1981	5.543	-5.433	3.245
1982	6.154	5.789	-4.251
1983	5.987	-6.123	4.789
1984	-5.866	6.354	-2.981
1985	6.564	6.411	3.544

将前 30 个的历史数据作为学习样本, 后 6 个的数据作为测试样本, 滑动点数为 1。通过试验本文设计广义回归神经的输入为 13, 得到子学习样本 16 个, 确定最优平滑参数为 0.145, 训练 GRNN 神经网络, 利用训练好的 GRNN 神经网络预测, 预测

结果进行“累减还原”。为了进行比较, 本文还对同样结构的广义回归神经网络 GRNN 和灰色 GM 模型进行了预测, 三种方法的预测误差见表 1。

由表 1 可以看出, 本文提出的串联 GM-GRNN 预测方法既有较好的预测能力, 比单一用灰色模型和单一用广义神经网络有更好的预测结果。

3 结论

由于中长期历史负荷数据比较少, 往往给预测带来很大的难度。虽然灰色预测理论证明可以对中长期负荷预测, 但是由于它理论上只适合预测呈近似指数增长规律的数据序列, 而且求解参数 a 和 u 的算法也有一些缺陷。但是灰色预测可以通过累加生成来削弱随机干扰的影响, 因此它可以作为 GRNN 的前期数据处理, 因此本文提出 GM-GRNN 预测方法并对我国某省年负荷做出预测, 结果表明这种预测方法是可行的, 为电力系统中长期负荷预测提供了一种新的预测途径。

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] 邓聚龙. 灰色系统理论[M]. 武汉: 华中理工大学出版社, 1990.
- [4] 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.
- [5] 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.
- [6] Specht D F. A General Regression Neural Network[J]. IEE Transactions on Neural Networks, 1991,2(6):568-576.
- [7] 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]. 震动测试与诊断, 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.
- [8] 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.

(下转第 53 页 continued on page 53)

表 3 迭代时间及次数比较

Tab.3 Comparison of iterative time and times

SDBP 模型		LMBP 模型		BRBP 模型	
迭代次数	迭代时间/s	迭代次数	迭代时间/s	迭代次数	迭代时间/s
3637.5	73.7	3.5	2.3	256.3	127.0

3 结论

1) 由于 BP 算法本身收敛速度慢, 且易陷入局部极小, 所以, SDBP 模型的预测误差, 尤其是峰值处预测误差较大, 预测结果并不理想。

2) 当网络具有相同结构参数时, 采用 BRBP 模型可使网络的推广能力得到提高, 平均相对误差和每日峰值相对误差降低, 但收敛速度过慢 (慢于 SDBP 模型), 不适于在实际应用中采用。

3) L-M 优化算法具有较快收敛速度及稳定性, 虽然经 LMBP 模型训练后的神经网络却对样本数据点实现了“过度拟合”, 但在负荷预测中, 平均相对误差较 SDBP 模型有了很大改善, 具有良好的应用前景。

参考文献

- [1] Park D C, El-Sharkawi M A, Marks R J, et al, Electric Load Forecasting Using an Artificial Neural Network[J]. IEEE Trans on Power Systems, 1991, 6(2):442-449.
- [2] Lee K, Cha Y, Park J. Short-term Load Forecasting Using Neural Network[J]. IEEE/PWRS 1991 Winter Meeting, 1991.
- [3] Peng T M, Hubele N, Karady G. Advancement in the Application of Neural Network for Short-term Load Forecasting[J]. IEEE/PWRS 1991 Summer Meeting, 1991.
- [4] Carpinteiro O A S, Reis A J R, da Silva A P A. A Hierarchical Neural Model in Short-term Load Forecasting[J]. Applied Soft Computing, 2004:405-412.

- [5] Kodogiannis V S, Anagnostakis E M. A Study of Advanced Learning Algorithms for Short-term Load Forecasting[J]. Engineering Applications of Artificial Intelligence, 1999:159-173.
- [6] Srinivasan D, et al. Parallel Neural Network-fuzzy Expert System Strategy for Short-term Load Forecasting System Implementation and Performance Evaluation[J]. IEEE Trans on Power Systems, 1999, 14(3): 1100-1106.
- [7] Kim Chang-il, Yu In-keun, Song Y H. Kohonen Neural Network and Wavelet Transform Based Approach to Short-term Load Forecasting[J]. Electric Power Systems Research, 2002, 63:169-176.
- [8] Hagan M T, Demuth, H B, Beale M H. Neural Network Design[M]. DAI Kui, et al trans. Beijing: China Machine Press, 2002.
- [9] Hornik K M, Stinchcombe M, White H. Multilayer Feedforward Networks are Universal Approximators[J]. Neural Networks, 1989, 2(5):359-366.
- [10] Hinton G E. Connectionist Learning Procedures[J]. Artificial Intelligence, 1989, 40:185-234.
- [11] Weigand A S, Rumelhart D E, Huberman B A. Generalization by Weight Elimination with Application to Forecasting[A]. In: Advances in Neural Information Processing Systems[C]. San Mateo(CA): Morgan Kaufmann. 1991. 575-582.
- [12] 许东, 吴铮. 基于 MATLAB6.X 的系统分析与设计——神经网络 (第二版) [M]. 西安: 西安电子科技大学出版社, 2002.

收稿日期: 2006-09-17; 修回日期: 2006-12-13

作者简介:

李晓波 (1973-), 女, 本科, 实验师, 主要从事自动化技术方面的实验教学及研究工作; E-mail:lixblh@163.com

罗枚 (1968-), 女, 硕士, 讲师, 主研领域为控制理论及控制应用。

(上接第 48 页 continued from page 48)

- [9] 张大海, 毕研秋, 等. 基于串联灰色神经网络的电力负荷预测方法[J]. 系统工程理论与实践, 2004, (12): 128-132.
ZHANG Da-hai BI Yan-qiu, et al Power Load Forecasting Method Based on Serial Grey Neural Network[J]. System Engineering Theory and Practice, 2004, (12):128-132.
- [10] 文艳, 宋宗勋, 张国柱, 等. 基于灰色关联-神经网络模型的城市电力负荷短期预测的研究与应用[J]. 继电器, 2005 33(19): 36-40.

WEN Yan, SONG Zong-xun, ZHANG Guo-zhu, et al. Research and Application of Grey-connection Neural-network Model in City Short-term Electric Power Load Forecast[J]. Relay, 2005 33(19): 36-40.

收稿日期: 2006-10-18

作者简介:

吴耀华 (1970-), 男, 讲师, 主要从事电力系统规划方面的研究。E-mail: wyh966@snut.edu.cn