

基于灰色神经网络组合模型的电力消费量预测

——以河北省为例

解 晗

(华北电力大学 经济管理系,河北 保定 071003)

摘 要:在分析灰色预测模型 GM(1,1)以及 BP 神经网络预测模型 2 种单一模型在电力消费量预测方面不足的基础上,提出灰色神经网络组合预测模型。以河北省电力消费量为基础,分别用 3 种模型进行预测,并加以比较分析。结果表明,灰色神经网络组合模型提高了关于河北省中长期电力消费量的预测精度,对河北省未来电力系统及能源需求规划具有一定参考价值。

关键词:GM(1,1);BP 神经网络;组合模型;电力消费量预测;河北省

中图分类号:F224

文献标志码:A

文章编号:1674-2494(2014)02-0055-06

随着河北省经济的快速增长,产业结构的不断升级,居民生活水平的显著提高,河北省电力消费量近年来快速增长,对电力消费量进行准确预测,特别是对电力消费量进行中长期预测,对河北省电力系统及能源需求规划、电力生产及电力安全运行,乃至对河北省经济能否健康发展都有十分重要的意义^[1]。影响电力消费量变化的因素很多,其中有一些因素可以准确地量化并加以计算,但大多数影响因素是复杂和不确定的。为了能够更加精确地对中长期电力消费量进行预测,近年来,国内外专家学者对预测方法进行了广泛而深入的探索,得到了许多有价值的方法及结论。这些预测方法大致分为三类:时间序列法(如指数平滑法、季节变动法等)、结构分析法(如回归分析法、指标分析法等)以及系统分析法(如神经网络方法、系统动力学方法等)^[2]。在对具体问题的预测方法选择中,往往采用两种或多种预测方法相结合的组合预测方法,把不同方法提供的不同方面的有效信息进行综合处理,可以更加充分地发掘利用原始数据的信息,弥补单一预测方法的不足,从而尽可能地提高预测精度^[3]。

灰色系统理论通过生成变换和关联分析等技术,为分析、处理贫瘠信息系统,进而探求其演化规律、建立预测模型,提供了有效的分析工具。同时它的原理过程简单易懂,对历史数据要求相对较少,运算处理方便,并且可以对预测结果进行有效检验,因此,灰色预测方法在电力行业已经得到了普遍应用^[4]。同时,由于电力系统是一个受多种因素影响的复杂非线性系统,电力消费量数据有时会出现过大或者过小的变化,从而无规律可循,神经网络模型具有很好的处理非线性变化的能力,对于非结构性、非精确性规律具有自适应和自主学习功能^[5]。因此,将灰色预测模型与人工神经网络模型进行组合处理,构建出灰色神经网络预测新模型,是提高预测精度的可行方法之一。

在分析了灰色 GM(1,1)预测模型以及 BP 神经网络预测模型 2 种单一模型在电力消费量预测方面不足的基础上,本文提出了灰色神经网络组合预测模型。通过对本文所提出的模型进行实证检验可以看出,组合预测模型同时吸收了 2 种单一模型的优点,弥补了单一模型的不足。在进行预测时,相对

收稿日期:2014-02-11

作者简介:解 晗(1989-),男,河北高阳人,硕士研究生,主要研究方向为电力工程技术及应用。

于任意单一模型,组合模型的预测精度有了进一步提高,因此该组合模型具有一定的实际应用价值。

一、组合预测模型的构建

1. 灰色系统理论及 GM(1,1) 预测模型

在控制论中,经常使用颜色的深浅来表示系统所包含信息的明确程度,“黑”表示系统信息完全未知,“白”表示系统信息完全可知,而“灰”代表系统信息不完全明确。综上,将信息完全未知的系统称为黑色系统,信息完全可知的系统称为白色系统,而系统信息不完全明确的系统称为灰色系统。灰色系统理论由我国学者邓聚龙教授于 1982 年提出,它的研究对象是部分信息已知、部分信息未知的“小样本”、“贫信息”不确定性系统,通过对部分已知信息进行分析及数据挖掘,实现对研究对象的确切描述和认识^[6]。由于河北省电力消费量增长受到经济发展水平、产业结构调整、居民收入水平及相关能源政策的影响,其中某些因素不能确定,因此可以将其视为灰色系统。

灰色预测的基本思想是:通过对原始时间序列进行数据预处理和灰色模型的建立,挖掘并掌握系统发展规律,对系统的未来发展趋势作出科学合理的定量预测。灰色预测模型有 GM(1,1)、GM(1,N) 及 GM(0,N) 等多种形式,其中 GM(1,1) 模型最为实用,也最为常见,它具有数据样本较少、原理简单、运算方便等特点,其中括号里的第一个“1”代表一阶方程,第二个“1”代表一个变量。GM(1,1) 建模方法如下^[7-9]:

首先,对包含 n 个变量的原始数据序列 $X^{(0)}=\{X^{(0)}(1), X^{(0)}(2), \dots, X^{(0)}(n)\}$ 进行一次累加生成处理,生成序列记为 $X^{(1)}$:

$$X^{(1)}=\{X^{(1)}(1), X^{(1)}(2), \dots, X^{(1)}(n)\},$$

其中, $X^{(1)}(k)=\sum_{i=1}^k X^{(0)}(i)$ 。

称 $\{X^{(1)}\}$ 为 $\{X^{(0)}\}$ 的一次累加生成序列,记为 1—AGO (Accumulating Generating Operation)。由于生成序列 $\{X^{(1)}\}$ 具有指数增长的规律,因此在构造一阶线性微分方程后,可得该方程的白化微分方程为:

$$\frac{dx^{(1)}}{dt} + aX^{(1)} = u。$$

若用离散形式表示,上式中 $\frac{dx^{(1)}}{dt}$ 可表示为:

$$\frac{\partial X^{(1)}}{\partial t} = \frac{X^{(1)}(k+1) - X^{(1)}(k)}{k+1-k} = X^{(1)}(k+1) - X^{(1)}(k) = a^{(1)}[X^{(1)}(k+1)] = X^{(0)}(k+1),$$

其中: $X^{(1)}$ 的值为: $\frac{1}{2}[X^{(1)}(k+1) + X^{(1)}(k)]$ 。因此,白化微分方程可表示为:

$$a^{(1)}[X^{(1)}(k+1)] + \frac{1}{2}a[X^{(1)}(k+1) + X^{(1)}(k)] = u,$$

利用最小二乘法求解:

$$\hat{A} = [\hat{a}, \hat{u}]^T = (B^T B)^{-1} B^T Y$$

$$B = \begin{pmatrix} -\frac{1}{2}[X^{(1)}(1) + X^{(1)}(2)] & 1 \\ -\frac{1}{2}[X^{(1)}(2) + X^{(1)}(3)] & 1 \\ \vdots & \vdots \\ -\frac{1}{2}[X^{(1)}(n-1) + X^{(1)}(n)] & 1 \end{pmatrix}, Y = \begin{pmatrix} X^{(0)}(2) \\ X^{(0)}(3) \\ \vdots \\ X^{(0)}(n) \end{pmatrix}。$$

根据上述计算,GM(1,1)模型的时间响应函数为:

$$X^{(1)}(k+1) = \left[X^{(1)}(1) - \frac{\hat{u}}{\hat{a}} \right] e^{-\hat{a}k} + \frac{\hat{u}}{\hat{a}},$$

对上式做累减还原,即得到原始数列 $X^{(0)}$ 的灰色预测模型为:

$$\hat{X}^{(0)}(k+1) = \hat{X}^{(1)}(k+1) - \hat{X}^{(1)}(k) = (1 - e^{-\hat{a}}) \left(X^{(0)}(1) - \frac{\hat{u}}{\hat{a}} \right) e^{-\hat{a}k} \quad (k=0, 1, 2, \dots).$$

当使用 GM(1,1)模型对实际问题进行预测时,如果原始数据序列增长率变化较为平缓时,其预测精度相对较高,但是当变化率较大或者出现数据有明显跳跃时,预测精度就会相对偏低。任何一种模型只能揭示研究对象某些方面的特征,但随着系统的发展演化,往往会有许多不确定因素以及产生的误差是单一模型难以对研究对象的内在规律进行全面的揭示或预测的,因此,有必要将 GM(1,1)预测模型与其他预测模型进行有机结合,从而提高研究对象的预测精度。

2. BP 神经网络预测模型

人工神经网络(Artificial Neural Network, ANN)是一种对人脑的抽象、简化和模拟,反映人脑基本特征的数学模型,是一种由大量处理单元(即神经元, Neurons)广泛互联而组成的网络^[10]。神经网络由分布于若干层的节点组成,它的构成随神经网络的类型和复杂程度的不同而不同。其中, BP 神经网络(Back Propagation Network)是目前在各类神经网络模型中最为广泛使用的神经网络模型之一。BP 神经网络实际上是一种多网络层的“逆推”学习算法,其基本思想是:学习过程由信号的正向传播与误差的反向传播两个过程组成。正向传播时,输入样本从输入层传入,经隐层依次处理后传向输出层。如果输出值与期望的输出值不符,则进行误差的反向传播。误差的反向传播是将输出误差以某种形式通过隐层向输入层逐层反向传播,并将误差分摊给各层的所有神经元,从而获得各层单元的误差信号,以误差信号作为修正各单元权值的依据。这种正向传播和反向传播的过程周而复始地进行,权值不断调整的过程,也就是神经网络学习训练的过程。此过程一直进行到网络输出的误差减少到可以接受的程度,或达到预设的学习次数为止。

BP 神经网络是一种单向传播的多层前馈网络,具有 3 层或 3 层以上的网络层数,包括输入层、中间层(隐含层)以及输出层,其结构如图 1 所示。

BP 神经网络预测模型的步骤如下^[11-12]:

1) 权值和阈值初始化:随机对全部权值和神经元的阈值赋以较小的初始值。

2) 给定输入值 X_k 和目标输出 Y_k 。

3) 通过神经网络得到实际输出值 \hat{Y}_k (正向过程)。

4) 进行权值的修正(反向过程):

$$W_{ij}^{(l)} = W_{ij}^{(l)} - \eta \frac{\partial E_k}{\partial W_{ij}^{(l)}} = W_{ij}^{(l)} - \eta \delta_j^l o_{ij}^l, \eta > 0,$$

式中: $W_{ij}^{(l)}$ 为第 l 层第 j 个神经元到第 $l+1$ 层第 i 个神经元的权系数; η 为增益项; δ_j^l 为第 l 层 i 节点的模式误差项,且有:

a) 若为输出节点,则




图 1 BP 神经网络的结构

$$\delta_{ij}^l = -\hat{Y}_k(1-\hat{Y}_k)(Y_k-\hat{Y}_k)。$$

b)若 i 为隐节点,则

$$\delta_{ij}^l = o_{ij}^l(1-o_{ij}^l) \sum_m \delta_{mk}^{(l+1)} W_{mi}^{(l+1)}。$$

5)达到误差精度要求,则输出结果,否则返回步骤 3)。

反复训练好的 BP 神经网络虽然可以使输出值与样本实际值的拟合达到相当高的精度,但在某些值的拟合、验证及预测过程中依然会产生相对大的偏差,其结果缺乏稳定性,故将 GM(1,1)模型与 BP 神经网络预测模型进行组合,可以弥补单一模型的不足,提高预测精度。

3. 灰色神经网络组合预测模型

设 g_1 为灰色 GM(1,1)模型电力消费量预测值, g_2 为 BP 神经网络电力消费量预测值,设 g_3 为加权平均组合电力消费量预测值,它们的预测误差分别为 ε_1 、 ε_2 和 ε_3 。

设 ω_1 和 ω_2 分别为 2 个模型的权系数,其中 $\omega_1+\omega_2=1$ 。于是有:

$$g_3 = \omega_1 g_1 + \omega_2 g_2,$$

则误差及方差分别求出:

$$\varepsilon_3 = \omega_1 \varepsilon_1 + \omega_2 \varepsilon_2, \text{VAR}(\varepsilon_3) = \omega_1^2 \text{VAR}(\varepsilon_1) + \omega_2^2 \text{VAR}(\varepsilon_2) + 2\omega_1 \omega_2 \text{COV}(\varepsilon_1, \varepsilon_2)。$$

以 ω_1 为变量,则 $\omega_2=1-\omega_1$,对 $\text{VAR}(\varepsilon_3)$ 求极小值,可以得到:

$$\omega_1 = \frac{\text{VAR}(\varepsilon_2) - \text{COV}(\varepsilon_1, \varepsilon_2)}{\text{VAR}(\varepsilon_1) + \text{VAR}(\varepsilon_2) - 2\text{COV}(\varepsilon_1, \varepsilon_2)}。$$

因此,由上式可知本文所提出的组合预测模型的权系数分别为:

$$\omega_1 = \frac{\text{VAR}(\varepsilon_2) - \text{COV}(\varepsilon_1, \varepsilon_2)}{\text{VAR}(\varepsilon_1) + \text{VAR}(\varepsilon_2) - 2\text{COV}(\varepsilon_1, \varepsilon_2)},$$

$$\omega_2 = \frac{\text{VAR}(\varepsilon_1) - \text{COV}(\varepsilon_1, \varepsilon_2)}{\text{VAR}(\varepsilon_1) + \text{VAR}(\varepsilon_2) - 2\text{COV}(\varepsilon_1, \varepsilon_2)}。$$

由于 2 个模型相互独立,故 $\text{COV}(\varepsilon_1, \varepsilon_2)=0$,所以:

$$\omega_1 = \frac{\text{VAR}(\varepsilon_2)}{\text{VAR}(\varepsilon_1) + \text{VAR}(\varepsilon_2)},$$

$$\omega_2 = \frac{\text{VAR}(\varepsilon_1)}{\text{VAR}(\varepsilon_1) + \text{VAR}(\varepsilon_2)}。$$

由上式可知:

$$\lim_{\text{VAR}(\varepsilon_1) \rightarrow \infty} \omega_1 = 0, \lim_{\text{VAR}(\varepsilon_1) \rightarrow 0} \omega_1 = 1, \lim_{\text{VAR}(\varepsilon_2) \rightarrow \infty} \omega_2 = 0, \lim_{\text{VAR}(\varepsilon_2) \rightarrow 0} \omega_2 = 1。$$

由上式可以看出,某一模型预测值越可靠,其权系数也就越大,故本文提出的组合预测模型优于任意一个单一模型。

二、实证分析

为了验证本文提出的灰色神经网络组合模型在实际预测中的效果,在对河北省年度电力消费情况及影响因素分析的基础上,对河北省电力消费量进行拟合及预测。根据上述模型的建模步骤及方法,采用 MATLAB 软件,对河北省 2000—2008 年的电力消费量数据运用灰色 GM(1,1)模型、BP 神经网络时间序列预测模型以及灰色神经网络组合预测模型进行拟合,并对 2009—2011 年的数据进行预测,拟合及预测结果如表 1、表 2 所示。其中,灰色 GM(1,1)预测模型的时间响应函数为:

$$X^{(1)}(k+1) = 5974.52e^{0.1315k} - 5403.99,$$

BP 神经网络预测模型的输入层节点数量为 3,分别为 3 年电力消费量数据;输出层节点数量为 1,即

表1 河北省2000—2008年度电力消费量拟合结果

年份	实际值 /亿千瓦时	GM(1,1)		BP神经网络		灰色神经网络组合模型	
		拟合值	相对误差/%	拟合值	相对误差/%	拟合值	相对误差/%
2000	809.340	774.021	4.364	865.026	6.880	818.441	1.124
2001	867.550	881.093	1.561	883.291	1.815	882.166	1.685
2002	965.830	1 002.977	3.846	922.392	4.497	963.644	0.226
2003	1 099.000	1 141.721	3.888	1 092.144	0.624	1 117.523	1.685
2004	1 291.402	1 299.659	0.639	1 159.399	10.221	1 231.198	4.662
2005	1 501.924	1 479.444	1.497	1 522.917	1.398	1 500.663	0.084
2006	1 734.832	1 684.099	2.924	1 734.651	0.010	1 708.774	1.502
2007	2 013.674	1 917.065	4.798	2 017.734	0.201	1 966.202	2.357
2008	2 095.019	2 182.257	4.164	2 094.569	0.022	2 139.457	2.121
平均拟合误差/%		3.08		2.85		1.72	

表2 河北省2009—2011年度电力消费量预测分析

年份	实际值 /亿千瓦时	GM(1,1)		BP神经网络		灰色神经网络组合模型	
		预测值	相对误差/%	预测值	相对误差/%	预测值	相对误差/%
2009	2 343.846	2 484.134	5.985	2 295.121	2.079	2 391.878	2.0492
2010	2 691.520	2 827.771	5.062	2 694.417	0.108	2 762.682	2.0644
2011	2 984.904	3 218.944	7.841	2 858.989	4.218	3 043.250	1.9550
平均预测误差/%		6.30		2.14		2.02	

第4年电力消费量数据;中间隐含层节点数量设置为5。最终组合预测模型中,灰色GM(1,1)预测模型的权系数 $\omega_1=0.512$,BP神经网络预测模型的权系数 $\omega_2=0.488$ 。

由表1及图2可知,灰色神经网络组合模型使实际拟合曲线更加平滑,平均拟合误差也低于GM(1,1)模型和BP神经网络预测模型,故可以验证灰色神经网络组合预测模型可以用于对电力消费量进行预测,针对河北省2009—2011年电力消费量的预测结果如表2所示。




图2 河北省2000—2008年度电力消费量拟合结果

由表2可知,组合模型的预测误差低于任意单一模型,因此该模型满足了电力消费量预测的精度要求,在中长期电力消费量预测中,具有一定的实际应用价值。

利用灰色神经网络组合预测模型,对河北省 2012—2015 年电力消费量进行预测,预测值如表 3 所示。

表 3 河北省 2012—2015 年电力消费量预测

年份	2012	2013	2014	2015
电力消费量	3 106.271	3 288.186	3 471.044	3 675.662

三、结论

本文将 GM(1,1)模型与 BP 神经网络模型相结合,较好地拟合了河北省电力消费量的发展趋势,提高了其预测精度,为河北省电力部门制定各项政策措施提供了科学依据。同时,由表 3 可以看到,河北省 2012—2015 年电力消费量呈现稳步增长态势,随着河北省工业化进程的加快和居民生活水平的提高,对电力的消费需求持续增长,电力供需依然面临较大压力。因此,如何合理调整电力消费结构、提高用电效率已经成为一个亟待解决的问题。

参考文献:

- [1]牛东晓. 电力负荷预测技术及其应用[M]. 北京:中国电力出版社,2009.
- [2]李 伟,韩 立. 组合灰色预测模型在电力负荷预测中的应用[J]. 重庆大学学报,2004(1):36-39.
- [3]牛东晓. 具有二重趋势性的季节型电力负荷预测组合优化灰色神经网络模型[J]. 中国电机工程学报,2002,22(1):29-32.
- [4]王赛爽,侯永辉. 灰色模型在中长期电力负荷预测中的应用[J]. 华北水利水电学院学报,2012(2):98-100.
- [5]李 萍. 基于 MATLAB 的 BP 神经网络预测系统的设计[J]. 计算机应用与软件,2008,4(25):149-151.
- [6]刘思峰,谢乃明. 灰色系统理论及其应用[M]. 北京:科技出版社,2008.
- [7]吕林正,吴文江. 灰色模型 GM(1,1)优化探讨[J]. 系统工程理论与实践,2001,21(8):92-96.
- [8]张 博,陶家祥,姚 远. 基于改进的 GM(1,1)模型的南京市用水量预测[J]. 水电能源科学,2011,29(3):24-26.
- [9]和志明,易娟子. 新疆原油产量的灰色组合预测研究[J]. 石油工业计算机应用,2010,68(4):3-6.
- [10]董长虹. Matlab 神经网络与应用[M]. 北京:国防工业出版社,2005.
- [11]王 捷,吴国忠,李艳昌. 蚁群灰色神经网络组合模型在电力负荷预测中的应用[J]. 电力系统保护与控制,2009,37(2):48-51.
- [12]林 芳. 灰色神经网络在粮食产量预测中的应用[J]. 计算机仿真,2012,29(4):225-228.

Electric Power Consumption Forecasting Based on Gray Neural Network Model

—Taking Hebei Province as an Example

Xie Han

(Department of Business Administration, Noth China Electric Power University, Baoding 071003, China)

Abstract: With the analysis of Gray model GM(1,1) and BP neural network model's deficiencies on the electric power consumption forecasting, this paper gives a combined gray neural network forecasting model. Based on the Electric Power Consumption in Hebei Province, three forecasting models are used to predict the Electric Power Consumption, and give a comparative analysis. The results show that the proposed combination model to further improve the prediction accuracy of long-term power consumption, and it has an application value.

Key words: GM(1,1); BP neural network; combined model; electric power consumption forecasting; Hebei Province

(责任编辑 陈 静)