

基于周期性截断灰色系统的电力负荷预测

张海宁¹, 王松¹, 郑征¹, 夏旻²

(1. 国网河南省电力公司经济技术研究院, 郑州 450052;

2. 南京信息工程大学江苏省大数据分析技术重点实验室, 南京 210044)

摘要: 电力负荷预测是电力系统调度和电力生产计划制定的重要依据; 电力负荷时间序列有着明显的周期性特征; 传统的电力负荷预测主要侧重于预测方法的研究, 而忽略了电力负荷数据周期性特性的分析, 影响了预测的准确性; 针对电力负荷时间序列的周期性特征, 提出了一种基于周期性截断的灰色系统模型来进行电力负荷预测; 该模型利用周期性截断来反映负荷数据的周期性特征, 提高了预测的精度; 仿真采用 EUNITE Network 的公开负荷数据进行算法性能的测试, 并与一些主流的电力负荷预测算法: BP 神经网络、极限学习机、自回归模型以及传统的灰色系统模型做比较; 仿真结果表明, 周期性截断的灰色系统负荷预测的归一化均方误差和绝对平均误差是最小的; 周期性截断的灰色系统为电力系统负荷预测提供了一种新的有效方法。

关键词: 电力负荷; 预测分析; 灰色系统; 周期性分析; 周期性截断

Power Load Forecasting Based on Periodic Truncated Grey System

Zhang Haining¹, Wang Song¹, Zheng Zheng¹, Xia Min²

(1. Economics and Technology Research Institute of State Grid Henan Electric Power Company, Zhengzhou 450052, China;

2. Jiangsu Key Laboratory of Big Data Analysis Technology, Nanjing University of Information Science and Technology, Nanjing 210044, China)

Abstract: Power load forecasting is an important basis for power system scheduling and power production planning. The power load time series has obvious periodicity characteristics. Traditional power load forecasting mainly focuses on forecasting methods, but ignores the analysis of periodic characteristics of power load data, which affects the accuracy of prediction. According to the periodic characteristics of power load time series, a grey system model based on periodic truncation is proposed to predict the power load. The model uses periodic truncation to reflect the periodic characteristics of load data and improves the prediction accuracy. Simulation uses EUNITE Network public load data to evaluate the performance of the algorithm, and compare with some mainstream power load forecasting algorithms: BP neural network, extreme learning machine, auto regression model and traditional grey system model. The simulation results show that the normalized mean square error and absolute mean error are minimum for the proposed method. The periodic truncated grey system provides a new effective method for power system load forecasting.

Keywords: power load; forecasting analysis; grey system; periodic analysis; periodic truncation

0 引言

电力是关系到国民经济各个领域的产业, 电力系统的可靠稳定的运行是社会各项事业稳定发展的基础。而负荷预测是电力系统至关重要的工作之一, 直接关系到电力系统的需求规划。准确的负荷预测可以有效地提高电网的规划调度能力, 提高电网运行的可靠性^[1]。另外, 负荷预测还是电网建设规划的重要依据。因此, 精准的负荷预测已经成为智能电网的重要标志之一。

负荷预测是一种典型的时间序列预测, 目前负荷预测的方法主要有传统的数学拟合方法、机器学习方法以及灰色系统理

论。传统的数学拟合的方法以自回归模型以及其衍生模型为代表, 主要有自回归滑动平均法 (Auto-Regressive and Moving Average ARMA) 以及累积自回归滑动平均 (Auto-regressive Integrated Moving Average ARIMA)^[2-4]。这类方法处理方式简单, 易于应用, 对数据量的要求也不高, 但是对数据的平稳性要求很高, 因此该类方法做负荷预测准确度不是很高。另一类负荷预测的方法是基于机器学习理论的, 目前主要有神经网络方法、支持向量机方法以及小波分析理论等^[5-7]。其中神经网络具有强大的非线性拟合能力, 并且有较强的适应性, 因此在负荷预测领域得到广泛的应用。但是, 神经网络也本身的缺陷, 例如学习的时候容易陷入局部最优、迭代次数不好确定、泛化误差比较大以及隐层神经元难以确定等。针对这些缺陷, 在负荷预测领域模糊与神经网络相结合、小波与神经网络相结合、极限学习机方法以及智能优化算法与神经网络相结合的方法被提出^[8-13]。近年来, 灰色系统理论也被广泛应用与负荷预测^[14-16]。灰色系统对于贫信息、不确定序列的预测有着本身的优势, 而电力负荷序列属于典型的贫信息、随机波动不确定系统, 因此负荷预测比较适宜采用灰色系统理论进行

收稿日期: 2017-08-27; 修回日期: 2017-09-16。

基金项目: 国家自然科学基金(61503192); 江苏省六大人才高峰(2014-XXRJ-007); 江苏省自然科学基金(BK20161533)。

作者简介: 张海宁(1971-), 女, 河南郑州市人, 高级工程师, 主要从事电力通信网络评估与规划方向的研究。

夏旻(1983-), 男, 江苏东台市人, 博士, 副教授, 主要从事大数据分析 & 机器学习理论方向的研究。

建模^[17]。

电力负荷序列从数据特征上有明显的周期性，即有年度周期性又有 24 小时周期性。但是目前所有的模型只是从数据本身进行建模分析，都没有很好的利用电力负荷序列的周期性特性。而数据的周期性特性对于序列预测而言是一个重要的辅助特性。为了能进一步提高负荷预测的准确性及稳定性，本文提出了一种周期性截断灰色系统来对电力负荷进行预测。该方法改变了传统的灰色 GM (1, 1) 的累加方式，通过周期截断累加生成操作实现序列的累加。这种周期性截断可以很好地反应出时间序列的周期性特征，为预测提供了更丰富的周期性信息，提高了预测的准确性及可靠性。实际负荷序列的测试表明本文提出的方法比传统的神经网络、极限学习机、自回归模型以及传统的灰色系统模型准确度更高。

1 电力负荷预测原理

研究一套处理过去和现在负荷的数学方法，在满足一定精度要求的意义下，确定未来某特定时刻的负荷数值，称为负荷预测。负荷数据是典型的时间序列数据，负荷预测就是针对对整个观测序列呈现出的某种随机过程的特性，去建立和估计产生实际序列的随机过程的模型，然后用这些模型去进行预测。它利用了电力负荷变动的惯性特征和时间上的延续性，通过对历史数据时间序列的分析处理，确定其基本特征和变化规律，预测未来负荷。

设负荷的历史数据为 $x_1, x_2, \dots, x_n, x_n$ 代表第 n 时间段的电力负荷数据。对于时间序列负荷预测而言，就是要寻找一个模型 $x_{n+1} = f(x_1, x_2, \dots, x_n)$ 能够准确地预测出下一个时间段的电力负荷值。灰色预测通过对电力负荷原始数据进行生成处理来寻找系统变动的规律，生成有较强规律性的数据序列，然后建立相应的微分方程模型，从而预测电力负荷未来发展趋势。

2 周期性截断的灰色系统预测模型

2.1 传统的灰色系统预测模型

在灰色系统模型中 GM (1, 1) 是最常见的，也是最核心的模型。该模型是一个包含单变量的微分方程模型，目前广泛应用与电力负荷的预测。G (1, 1) 模型首先对序列进行累加生成 (AGO)，然后用典型的曲线进行趋势的逼近，达到预测的目的。设 $x^{(0)} = (x^{(0)}(1), x^{(0)}(2), \dots, x^{(0)}(n))$ 为原始数列， n 为数列元素的个数。那么灰色系统的一次累加生成数列表示为 $x^{(1)} = (x^{(1)}(1), x^{(1)}(2), \dots, x^{(1)}(n))$ ，其中 $x^{(1)}(k) = \sum_{i=1}^k x^{(0)}(i), k = 1, 2, \dots, n$ ，建立一介微分方程拟合灰色系统为：

$$\frac{dx^{(1)}(t)}{dt} + ax^{(1)}(t) = b \tag{1}$$

对于离散系统，求解上述方程可以得到第 $k + 1$ 个累加序列的估计值为：

$$\hat{x}^{(1)}(k + 1) = \left(x^{(0)}(1) - \frac{b}{a}\right)e^{-ak} + \frac{b}{a} \tag{2}$$

由公式 (2) 可知，序列中 $x^{(0)}(k + 1)$ 的预测值 $\hat{x}^{(0)}(k + 1)$ 为：

$$\hat{x}^{(0)}(k + 1) = \hat{x}^{(1)}(k + 1) - \hat{x}^{(1)}(k) \tag{3}$$

传统的基于灰色系统的负荷预测都是基于以上模型进行的。

2.2 周期性截断的灰色系统的设计

在现实生活中，许多序列具有周期性的特点，比如电力负荷数据。电力负荷数据表现为多周期性特性，每 24 小时的负荷为一个周期，每一个星期的负荷数据为一个周期，一年的用电负荷也为一个周期。然而，GM (1, 1) 预测模型的累加操作 (AGO) 不能体现出这种周期性，它经常导致结果出现指数的衰减或增加。因此，利用 GM (1, 1) 模型来对有周期性特性的序列存在着不足。如何将周期性特性考虑进灰色系统来提高预测的准确性是一个值得研究的课题。基于此，本文提出了累加生成周期截断的一种新方法进行周期性特性的提取，周期截断累加生成操作为：

$$x^{(1)}(k) = \sum_{j=1}^q x^{(0)}(k + j - 1) \tag{4}$$

其中： $k = 1, 2, \dots, n - q + 1, q$ 是数据序列的周期。周期性的离散灰色预测模型为：

$$x^{(1)}(k) - x^{(1)}(k - 1) + ax^{(1)}(k) = b \tag{5}$$

公式 (5) 可以记做：

$$x^{(1)}(k + 1) = d_1 x^{(1)}(k) + d_2 \tag{6}$$

其中： $d_1 = \frac{1}{a + 1}, d_2 = \frac{b}{a + 1}$ 。我们可以得到：

$$x^{(1)}(2) = d_1 x^{(1)}(1) + d_2$$

$$x^{(1)}(3) = d_1 x^{(1)}(2) + d_2$$

⋮ ⋮ ⋮

$$x^{(1)}(n - q + 1) = d_1 x^{(1)}(n - q) + d_2$$

将上述方程组简化为：

$$Q = [x^{(1)}(2), x^{(1)}(3), x^{(1)}(4), \dots, x^{(1)}(n - q + 1)]^T$$

$$A = \begin{bmatrix} x^{(1)}(1) & x^{(1)}(2) & x^{(1)}(3) & \dots & x^{(1)}(n - q) \\ 1 & 1 & 1 & \dots & 1 \end{bmatrix}^T$$

$$d = [d_1, d_2]^T$$

由上述可知 $Q = Ad$ ，可以得到 $A^T A d = A^T Q, d = (A^T A)^{-1} A^T Q$ ，将 d_1, d_2 代入式 (9)，则有：

$$\hat{x}^{(1)}(k + 1) = d_1 x^{(1)}(k) + d_2 =$$

$$d_1 (d_1 x^{(1)}(k - 1) + d_2) + d_2 = \dots =$$

$$d_1^m x^{(1)}(k - m + 1) + (d_1^{m-1} + d_1^{m-2} + \dots + d_1 + 1)d_2 =$$

$$d_1^m \left(x^{(1)}(k - m + 1) - \frac{d_2}{1 - d_1}\right) + \frac{d_2}{1 - d_1}$$

对于预测而言，最近的数据比之前的数据对结果的影响更大，因为最近的数据可以提供更多的趋势信息。因此，本文利用如下的解决方案：

$$\hat{x}^{(1)}(k + 1) = d_1 x^{(1)}(k) + d_2 \tag{7}$$

为了解决数据的迭代对预测结果的影响，本文在公式 (7) 中加入修正参数 l ，那么公式 (7) 变为：

$$\hat{x}^{(1)}(k + 1) = d_1 (x^{(1)}(k) + l) + d_2 \tag{8}$$

通过公式 (8)，可以用无约束的最小二乘得到参数 l 的值，使 $\hat{x}^{(1)}(k)$ 和 $x^{(1)}(k)$ 误差平方的总和最小即：

$$\min S = \min_{\lambda} \sum_{i=2}^k [\hat{x}^{(1)}(i) - x^{(1)}(i)]^2 \tag{9}$$

由上述优化得到 l 的估计为：

$$l = \frac{\sum_{i=1}^{k-1} [x^{(1)}(i+1) - d_1 x^{(1)}(i) - d_2]}{d_1(k-1)} \quad (10)$$

通过上述过程, 数据 $x^{(0)}(k+1)$ 可被估算为:

$$\hat{x}^{(0)}(k+1) = \hat{x}^{(1)}(k-q+2) - x^{(1)}(k-q+1) + x^{(0)}(k-q+1) \quad (11)$$

由方程 (11) 可知, $x^{(0)}(k+1)$ 的预测值由两部分组成: $\hat{x}^{(1)}(k-q+2) - x^{(1)}(k-q+1)$ 和 $x^{(0)}(k-q+1)$ 。其中 $x^{(0)}(k-q+1)$ 是 $x^{(0)}(k+1)$ 的上一个周期值, $\hat{x}^{(1)}(k-q+2) - x^{(1)}(k-q+1)$ 是基于 $x^{(0)}(k-q+1)$ 的修改值, 可以看作是新一周期的一个趋势变量。

上述方法从理论上讲是可靠的, 从自回归的角度出发,

$x^{(0)}(k+1) = \sum_{i=1}^q p_i x^{(0)}(k-i+1)$, $P_{(k-q+1)}$ 是 p_i 中最大的系数, 这就表明 $x^{(0)}(k-q+1)$ 影响 $x^{(0)}(k+1)$ 的关键值, 因此, 本文的方法是可靠的。

3 电力负荷预测实例分析

本文采用 EUNITE Network 的公开测试数据集来验证本文所提方法的可靠性。该数据为斯洛伐克东部电力公司长达两年的每 30 分钟的真实电力负荷数据。

图 1 给出了该数据的全部 730 天的每天中每半个小时的电力负荷数据。由图 1 可以看出电力负荷数据在年份上也表现出明显的周期性, 730 天的数据正好是两个周期。图 2 给出了每天的电力负荷曲线, 为了比较清晰的表示该曲线, 本文中截取了其中的 50 天的负荷数据。从图 2 可以看出, 电力负荷的数据呈现出明显的周期性, 周期是以一个星期为单位的。另外, 对于数据分析发现负荷序列还是一个以 24 小时为周期的一个时间序列。图 3 为截取的序列中连续 6 天的负荷数据。从图 3 可以看出, 该序列明显的呈现周期性, 并且周期为 24 小时。综上所述可以看出, 负荷序列呈现出多周期性, 这样的多周期性特征可以很好的辅助多尺度的预测, 但是针对按天负荷预测以及按小时的短期负荷预测, 目前还没有将这种周期性考虑进负荷预测的模型出现, 如图 1 和图 2 所示。




图 1 两年的电力负荷三维图

电力负荷序列从数据特征上有明显的周期性。数据的周期性特性对于序列预测是一个重要的辅助特性。为了有效利用序列的周期性特征来提高预测的准确性, 本文利用一种周期性截断灰色系统来对电力负荷进行预测。该方法通过周期截断累加生成操作实现序列的累加, 实现序列周期性特征的表达。并且采用该方法后, 时间上最近的一个周期对预测结果的影响最




图 2 每天的电力负荷曲线

大, 也符合实际的序列预测分析, 如图 3。




图 3 每半小时的电力负荷示例曲线

为了将本文模型与其他方法作比较, 本文采用归一化均方误差 (NMSE) 和绝对平均误差 (MAPE) 作为误差准则, 归一化均方误差定义为:

$$NMSE = \frac{\sum_{i=1}^M (y_i - \tilde{y}_i)^2}{\sum_{i=1}^M y_i^2}$$

其中: y_i 是原数据, \tilde{y}_i 是预测数据, M 代表预测点的数量。另一个测量法则称为绝对平均误差 (MAPE)。绝对平均误差被视为标准的统计性能指标之一:

$$MAPE = \frac{1}{M} \sum_{i=1}^M \left| \frac{y_i - \tilde{y}_i}{y_i} \right| \cdot 100\%$$

已有的文献中电力负荷预测的正确率通常采用 MAPE 作为评价指标^[11], 本文中为了更加有效地反映算法的可信性采用了 NMSE 和 MAPE 两种指标。为了证明本文方法的有效性, 本文将所提方法的结果与传统神经网络 (ANN), 自回归模型 (AR), 极限学习机模型 (ELM) 以及灰色系统 G (1, 1) 模型做对比。本文进行了两个尺度的电力负荷预测, 一个是以天为单位, 一个是以半小时为单位。图 4 给出了几种不同方法的按天负荷预测结果, 为了更好地展示预测结果, 本文中截取了其中 2 个周期进行显示。在这个测试中, 预测第 651 天至 730 天的负荷。以按天负荷预测时, 本文选取的截断周期为 7 天。ANN 以及 ELM 的输入也为预测数据的前 7 个数据, AR 的拟合也是由预测数据的前 7 个负荷数据进行的。但是由于 ANN 以及 ELM 的训练只是整个样本集上的拟合, 因此周期性很难被直接利用。而 AR 本身是对所有数据集的整体拟合, 周期性也很难利用。从图 4 可以看出, 本文方法在按天负荷预测方面比其它几种方法准确度更高。几种具体的预测误差如表 1 所示。可以看出本文的方法利用了周期性特征以后, 预测结果明显要好于其他方法。AR 由于本身线性拟合的缺陷导致预测结果最差。GM (1, 1) 由于没有周期性截断, 导致

累加数据过长, 严重影响了预测精度。ANN 和 ELM 有很好的非线性拟合能力, 因此结果比 AR 和 GM(1, 1) 要优。由于 ELM 学习的时候是全局最优的, 而 ANN 有时容易陷入局部最优, 因此 ELM 的预测精度比 ANN 略高, 如图 4 和表 1 表示。




图 4 不同方法的按天负荷预测对比

表 1 不同方法的按天负荷预测对比结果

	ANN	AR	ELM	GM(1,1)	本文方法
NMSE	0.041	0.059	0.039	0.049	0.018
AMPE	2.0%	2.4%	1.9%	2.3%	1.4%

图 5 给出了几种不同方法的按半小时负荷预测结果, 为了更好的展示预测结果, 本文中截取了其中 1 个周期进行显示。在这个测试中, 预测最后 4 天的数据。以按半小时负荷预测时, 本文选取的截断周期为 24 小时。ANN 以及 ELM 的输入也为预测数据的前 48 个数据, AR 的拟合也是由预测数据的前 48 个负荷数据进行的。从图 5 可以看出, 本文方法的预测拟合效果要优于其它方法。表 2 给出了几种方法的具体预测结果对比, 如图 5 和表 2 所示。




图 5 不同方法的按半小时负荷预测对比

表 2 不同方法的按半小时负荷预测对比结果

	ANN	AR	ELM	GM(1,1)	本文方法
NMSE	0.066	0.123	0.061	0.097	0.039
AMPE	1.8%	2.5%	1.7%	2.0%	1.2%

通过上述对比试验可以看出, 不论是按天预测还是按半小时进行预测, 采用周期截断累加生成操作的灰色系统比传统的负荷预测方法准确度和预测稳定性都更高。

4 结论

电力负荷的预测对电力系统调度和电力生产计划制定有着重要影响。电力负荷时间序列有着明显的周期性特征。但是目前所有的模型只是从数据本身进行建模分析, 都没有很好地利用电力负荷序列的周期性特性。而数据的周期性特性对于序列预测而言是一个重要的辅助特性。为了能进一步提高负荷预测

的准确性及稳定性, 本文提出了一种周期性截断灰色系统来对电力负荷进行预测。该方法改变了传统的灰色系统的累加方式, 通过周期截断累加生成操作实现序列的累加, 并且利用一个修正参数来提高预测的准确性和可靠性。该模型有效的利用了序列的周期性特性, 提高了预测的准确性及可靠性。通过两个实际负荷序列的测试表明本文提出的方法比传统的神经网络、极限学习机、自回归模型以及传统的灰色系统模型准确度更高。

参考文献:

- [1] 肖白, 周潮, 穆钢. 空间电力负荷预测方法综述与展望 [J]. 中国电机工程学报, 2013, 33 (25): 78-92.
- [2] Liu M, Shi Y, Fang F. Load Forecasting and Operation Strategy Design for CCHP Systems Using Forecasted Loads [J]. IEEE Transactions on Control Systems Technology, 2015, 23: 1672-1684.
- [3] 孙晓磊, 丁亚委, 郭克余, 等. 基于 ARMA 模型的船舶海水冷却系统参数预测 [J]. 计算机测量与控制, 2017 (7): 285-289.
- [4] 宋晓茹, 李莉, 张来青. 中长期电力负荷预测研究 [J]. 计算机仿真, 2014, 31 (9): 132-135.
- [5] Xie J R, Chen Y, Hong T, et al. Relative Humidity for Load Forecasting Models [J]. IEEE Transactions on Smart Grid, 2016: 1-1.
- [6] Wilamowski B M, Cecati C, Kolbusz J, et al. A Novel RBF Training Algorithm for Short-term Electric Load Forecasting and Comparative Studies [J]. IEEE Transactions on Industrial Electronics, 2015, 62 (10): 1-1.
- [7] 王惠中, 刘轲, 周佳, 等. 电力系统短期负荷预测建模仿真研究 [J]. 计算机仿真, 2016, 33 (2): 175-179.
- [8] Li S, Wang P, Goel L. Short-term load forecasting by wavelet transform and evolutionary extreme learning machine [J]. Electric Power Systems Research, 2015, 122: 96-103.
- [9] Li S, Goel L, Wang P. An ensemble approach for short-term load forecasting by extreme learning machine [J]. Applied Energy, 2016, 170: 22-29.
- [10] Sousa J C, Jorge H M, Neves L P. Short-term load forecasting based on support vector regression and load profiling [J]. International Journal of Energy Research, 2014, 38 (38): 350-362.
- [11] 宁晓光, 朱永利. 基于增量优化极限学习机的电力负荷预测 [J]. 计算机仿真, 2016, 33 (2): 163-166.
- [12] 王蕾, 张九根, 李腾, 等. 基于改进 BP 神经网络的中央空调冷负荷预测研究 [J]. 计算机测量与控制, 2014, 22 (6) 1690-1692.
- [13] 肖勇, 杨劲锋, 马千里, 等. 基于模块化回声状态网络的实时电力负荷预测 [J]. 电网技术, 2015, 39 (3): 804-809.
- [14] 张健美, 周步祥, 林楠, 等. 灰色 Elman 神经网络的电网中长期负荷预测 [J]. 电力系统及其自动化学报, 2013, 25 (4): 145-149.
- [15] 王大鹏, 汪秉文. 基于变权缓冲灰色模型的中长期负荷预测 [J]. 电网技术, 2013, 37 (1): 167-171.
- [16] 吴潇雨, 和敬涵, 张沛, 等. 基于灰色投影改进随机森林算法的电力系统短期负荷预测 [J]. 电力系统自动化, 2015, 39 (12).
- [17] 焦润海, 苏辰隽, 林碧英, 等. 基于气象信息因素修正的灰色短期负荷预测模型 [J]. 电网技术, 2013, 37 (3): 720-725.