

# BP 神经网络误差修正的电力物资时间序列预测<sup>①</sup>

赵一鹏<sup>1,2</sup>, 丁云峰<sup>1</sup>, 姚恺丰<sup>3</sup>

<sup>1</sup>(中国科学院 沈阳计算技术研究所, 沈阳 110168)

<sup>2</sup>(中国科学院大学, 北京 100049)

<sup>3</sup>(国家电网公司东北分部, 沈阳 110180)

**摘要:** 传统的 ARIMA 时间序列分析方法是基于线性技术来进行时序预测, 而对非线性数据的处理不尽合理, 效果欠佳; 而影响电力物资需求的因素非常多, 绝大多数的物资序列通常既包含了线性时序的部分, 又包含了非线性时序的成分. 本文提出在 ARIMA 对电力物资需求预测的基础上, 融合 BP 神经网络进行误差修正, 以全面提取物资序列中的复合特征, 提高电力物资的预测精度. 实验结果表明, 误差修正后的电力物资预测精度有了显著提高, 可以为制定物资采购计划提供重要的数据支持.

**关键词:** 时间序列; ARIMA 模型; BP 神经网络; 误差修正; 电力物资预测

引用格式: 赵一鹏, 丁云峰, 姚恺丰. BP 神经网络误差修正的电力物资时间序列预测. 计算机系统应用, 2017, 26(10): 196-200. <http://www.c-s-a.org.cn/1003-3254/6011.html>

## Time Series Prediction of Power Supplies Based on BP Neural Network Error Correction

ZHAO Yi-Peng<sup>1,2</sup>, DING Yun-Feng<sup>1</sup>, YAO Kai-Feng<sup>3</sup>

<sup>1</sup>(Shenyang Institute of Computer Technology, Chinese Academy of Sciences, Shenyang 110168, China)

<sup>2</sup>(University of Chinese Academy of Sciences, Beijing 100049, China)

<sup>3</sup>(Northeast Branch of State Grid Corporation of China, Shenyang 110180, China)

**Abstract:** The traditional ARIMA time series analysis method is based on the linear technology to predict the time series, while its processing of nonlinear data is not reasonable with poor effect. There are many factors influencing the demand of power supply, and most of the material sequences usually contain both the linear time series and the nonlinear time series. In this paper, based on the ARIMA forecast, the BP neural network is combined with error correction to extract the composite features in the material sequence in order to improve the forecast precision of the electric power materials. The experimental results show that the accuracy of power supply forecasting with error correction can be improved significantly, which can provide important data support for material procurement plan.

**Key words:** time series; ARIMA model; BP neural network; error correction; electric power supplies forecasting

随着电力企业的快速发展, 物资管理在企业精细化运营过程中越显重要. 目前, 国家电网公司物资集约化管理以及采购管控要求不断提高, 给各网省电力公司物资管理提出了更高的要求, 如何申报合理的物资需求数量成为各网省电力公司亟待解决的问题. 电力物资需求预测的目的就是通过对未来一段时间内物资需求量的科学、合理的预测, 为企业制定合理的物资

需求规划提供可靠的数据支持, 为物资采购打下良好的基础, 有效提高企业物资管理的前瞻性, 为企业提前统筹资源创造有利条件. 物资需求预测是现代电网企业合理制定采购计划、规划未来发展战略所需要的一项重要能力, 同时也是提升电网运作能力的重要手段<sup>[1,2]</sup>.

从目前国内外的相关研究上来看, 在物资预测研究方面已经有很多理论和方法. Unlu 通过运用移动平

① 收稿时间: 2017-01-18; 采用时间: 2017-02-23

均法、指数平滑法以及线性回归等模型,依据历史需求数据进行预测,引用误差均方差最小的模型的预测结果作为未来需求的估计<sup>[3]</sup>,这主要是针对线性序列的预测.为了改善非线性时间序列的预测效果,许多非线性方法的研究日益受到关注.宋斌针对我国电网建设项目物资的需求特点,基于BP神经网络方法对电网建设项目物资进行了预测<sup>[4]</sup>.韩戟提出一种基于支持向量机(SVM)的电力行业物资需求预测方法,把物资需求审核转化为分类问题,实现了物资采购数量和种类的审核<sup>[5]</sup>.在电力预测领域,李晨熙结合小波变化和ARIMA模型对短期电力负荷进行了预测<sup>[6]</sup>.

电力物资需求预测的特点是:电力物资作为一个时间序列具有一定的周期性、趋势性以及自相关性,同时由于其受到恶劣天气地形、国家政策、电力系统运行情况等多种复杂因素的影响,电力物资序列中表现出很强的波动性,在现实中,绝大多数物资时间序列,通常既包含了线性时序的成分,又包含了非线性时序的成分,呈现出线性和非线性的复合特征.由于电力物资需求数据常常是具有一定周期性和趋势性的自相关时间序列,ARIMA模型能比较有效地处理这类序列.采用恰当的ARIMA模型预测后所得的残差应该是白噪声,在线性时间序列分析中,白噪声序列已经没有分析价值了,但是通过非线性时间序列分析可以提取出其剩余有价值信息,BP神经网络具有自学习、自适应能力以及良好的非线性映射能力,对剩余信息进行提取并修正ARIMA预测结果是合适的.本文在ARIMA模型的基础上进行改进,首先用ARIMA对电力物资进行预测,然后用BP神经网络对其结果进行误差修正,得到最终的物资需求预测值.

## 1 ARIMA 时间序列预测法

时间序列预测模型在线性系统、平稳时间序列问题上得到了广泛的应用.时间序列预测是对电力物资需求量时间序列本身所体现出的随时间变化而变化的规律来分析完成物资需求量的预测.时间序列分析法包括自回归(AR)、移动平均法(MA)、自回归移动平均法(ARMA)和差分自回归移动平均模型(ARIMA)等.

### 1.1 ARIMA 模型

ARIMA模型通常被写作 $ARIMA(p, d, q)$ ,其中,

$p$ 表示自回归阶数, $d$ 表示差分次数, $q$ 表示移动平均阶数.ARIMA模型实质是先对非平稳的时间序列 $y_t$ 进行 $d$ 次差分处理得到新的平稳的数据序列 $r_t$ ,将 $r_t$ 拟合ARMA( $p, q$ )模型,然后再 $d$ 次差分还原,便可得到原序列 $y_t$ 的预测数据.其中,ARMA( $p, q$ )的一般表达式为:

$$r_t = \varphi_0 + \sum_{i=1}^p \varphi_i r_{t-i} + e_t - \sum_{i=1}^q \theta_i e_{t-i} \quad (1)$$

式中,前半部分为自回归部分, $p$ 为自回归阶数, $\varphi_i (i=1, 2, \dots, p)$ 为自回归系数,后半部分为滑动平均部分, $q$ 为滑动平均阶数, $\theta_i (i=1, 2, \dots, q)$ 为滑动平均系数, $e_t$ 为白噪声.

ARIMA法<sup>[7]</sup>是处理动态数据的一种有效分析方法,是时间序列中最具代表性、使用最广泛的模型,当不同参数取0时可以简化为其它模型,如图1所示.ARIMA模型在社会、经济、股票等众多领域中都有着广泛的应用,对于线性时间序列有着卓越的预测能力.因而,本文选取ARIMA模型来对电力物资的月需求量进行分析预测,ARIMA模型的建模流程如图2所示.

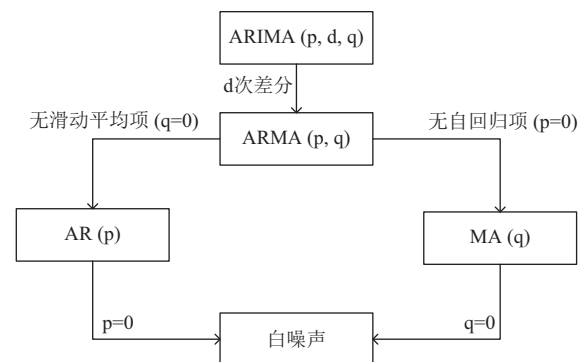


图1 各模型间的转化

### 1.2 ARIMA 模型的特点和不足

ARIMA模型简洁,计算速度快,在时间序列预测的领域应用广泛,它对时间序列具有较高的拟合能力和预测能力.ARIMA模型的最大缺陷是,序列变量的未来值被假定满足变量过去观测值和随机误差的线性函数关系,这点从式(1)中也可以看出来,由于ARIMA方法是基于线性关系来进行时序预测的,因此很难有效地捕捉并解释非线性关系.所以单独使用ARIMA模型对电力物资进行预测,对物资需求背后隐含的非线性关系挖掘得不充分.在ARIMA预测的基础上充分挖掘非线性信息正是我们可以改进的地方.

ARIMA 模型使用显式表达式来描述数据间的相互关系. 然而, 非线性数据间的关系一般都很复杂, 很难用一种方法把变量之间的结构用数学语言表达出来. 神经网络模型具有较强的学习和数据处理能力, 是一种自然非线性建模过程, 能够挖掘数据背后复杂的甚至很难用数学式描述的非线性特征, 且不需要事先假设数据之间具有何种函数形式或满足哪种分布条件. BP 神经网络具有极强的非线性映射能力, 这启发人们把人工神经网络技术引入到时间序列分析中来, 即不去关系具体用什么样的非线性组合, 而是用人工神经网络去逼近那个未知的最佳映射, 因此利用它对电力物资市场的动态过程进行建模是合适的.

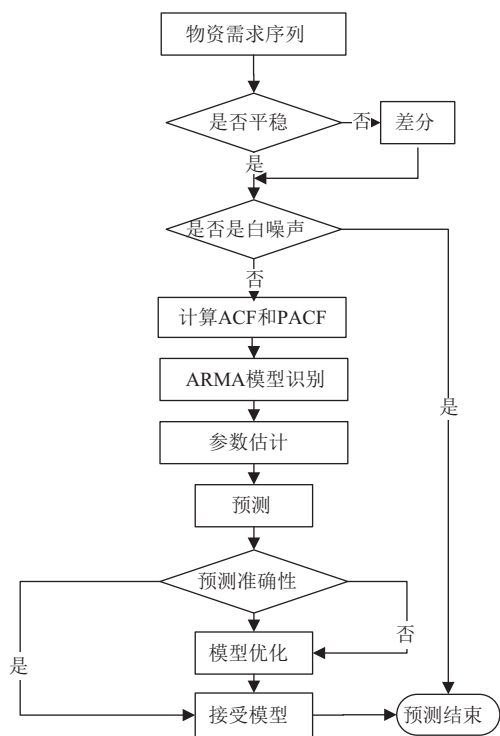


图2 ARIMA 建模流程

## 2 BP 神经网络

近年来, 神经网络的研究在国内外广泛兴起. 神经网络作为一种通用的非线性函数逼近工具, 以其良好的非线性品质、灵活而高效的自组织学习方法等特点, 具体使用时, 不需要对时间序列进行诸如平稳性等假设, 在预测领域中显出了很大的优势.

BP 神经网络<sup>[8-10]</sup>是一种多层前馈型神经网络, 该网络的主要特点是信号前向传递, 误差反向传播. 在前向传递中, 输入信号从输入层经隐含层逐层处理, 直至输出层. 每一层的神经元状态只影响下一层神经元状

态. 如果输出层得不到期望输出, 则转入反向传播, 根据预测误差调整网络权值和阈值, 从而使 BP 神经网络预测输出不断逼近期望输出. 采用反向传播学习算法 (Back-Propagation) 来调整权值, 可以实现从输入到输出的任意非线性映射. 目前, 在人工神经网络的实际应用中, 绝大部分的神经网络模型都采用 BP 神经网络及其变化方式, 它也是前馈网络的核心部分, 体现了人工神经网络的精华, 其建模流程如图 3.

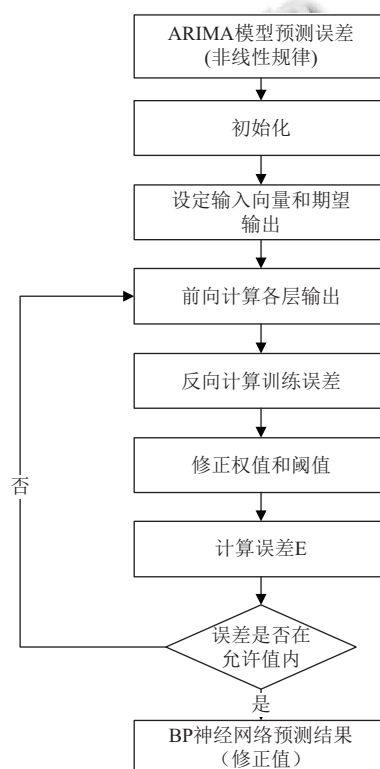


图3 BP 神经网络预测流程

## 3 ARIMA 模型的改进算法

电力物资需求时间序列可以看成是由一个线性结构和一个非线性结构两部分组成, 单纯使用 ARIMA 模型或 BP 神经网络都有可能致误差过大. 为了提高单一模型的预测效果, 在其它领域也出现了一些组合模型<sup>[11,12]</sup>, 其主要形式是对单个预测方法进行加权平均, 其研究重点为加权系数的确定. 加权系数直接影响组合模型的预测效果, 但如何确定加权系数是一件非常困难的事情, 在实际应用中带有强烈的随意性和主观性. 基于此, 本文提出首先使用 ARIMA 模型对电力物资需求量进行预测, 将预测的残差序列 $\{e_t\}$ 作为神经网络的输入 (如图 4), 使用 BP 神经网络进行预测, 根据 BP 神经网络的误差预测值对 ARIMA 模型的初始

预测值进行修正, 得到最终的预测结果. 具体步骤如下:

电力物资的时间序列  $y_t$  可以看成是由线性自相关结构  $L_t$  与非线性结构  $N_t$  两部分组成的, 即:

$$y_t = L_t + N_t \quad (2)$$

(1) 使用 ARIMA 模型对电力物资需求量时间序列  $y_t$  的线性部分进行预测, 设预测结果为  $\hat{L}_t$ , 原序列与  $\hat{L}_t$  的残差为  $e_t$ , 那么有:

$$e_t = y_t - \hat{L}_t \quad (3)$$

(2) 残差序列  $\{e_t\}$  中隐含了原序列中的非线性关系, 我们用 BP 神经网络来逼近这种非线性关系, 将预测的残差序列  $\{e_t\}$  作为神经网络的输入 (如图 4), BP 神经网络的阈值和权值一般是随机产生的, 用 BP 算法对其进行训练, 求得最优权值和阈值, 假设神经网络有  $n$  个输入, 这个残差序列关系可写成:

$$e_t = f(e_{t-1}, e_{t-2}, \dots, e_{t-n}) + \varepsilon_t \quad (4)$$

这里,  $f$  是由神经网络决定的非线性函数,  $\varepsilon_t$  是随机误差, 通过 BP 神经网络估计的残差序列  $\{e_t\}$  的预测值记为  $\hat{N}_t$ .

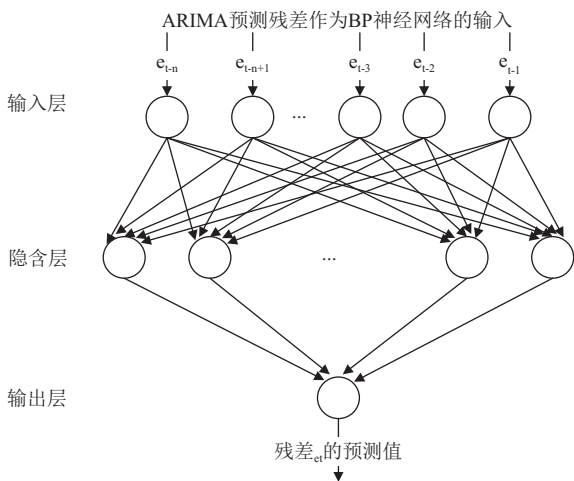


图4 BP神经网络模型

(3) 把两个模型预测的结果相加得到最终修正后的预测结果为:

$$\hat{y}_t = \hat{L}_t + \hat{N}_t \quad (5)$$

从预测过程看, ARIMA 模型用于线性部分的预测, 而 BP 用于非线性部分预测, 通过对 ARIMA 和 BP 的综合运用, 充分发挥了这两种模型的长处, 从而提高了预测精度. 经过 BP 神经网络误差修正后的 ARIMA 模型可以提取出物资需求序列中的绝大部分

数据特征.

## 4 实验及分析

### 4.1 实验步骤

步骤一. ARIMA 模型预测铝绞线序列的线性部分. 先做出钢芯铝绞线需求量的时序图 (图 5), 从图 5 可以看出该序列具有明显的增长趋势, 并且包含周期为 12 个月的季节波动. 为了消除增长趋势, 同时减小序列的波动性, 对铝绞线需求量数据做一阶自然对数逐期差分, 接着对其做季节差分消除季节性, 经试验, 二阶季节差分后序列的季节性并没有得到显著的改善, 故只做一阶季节差分即可. 通过 R 语言编程分析差分后的物资序列的自相关和偏自相关函数, 并结合 AIC 和 SBC 等信息准则, 最终选取 ARIMA(1, 1, 1)(1, 1, 1)<sup>12</sup> 作为钢芯铝绞线月度需求量的预测模型.




图5 钢芯铝绞线月需求量时序图

步骤二. 使用 BP 神经网络对步骤一中的预测误差进行拟合. 先利用公式 (6) 将样本数据归一化到 [0, 1]. 鉴于物资序列的周期性特点, 输入层节点数取 12 或 6, 输出层节点数为 1, 隐层节点数首先根据经验公式 (7) 确定大致范围, 然后用试凑法确定最佳的节点数:

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (6)$$

$$m = \sqrt{n+1} + a \quad (7)$$

其中,  $m$  为隐层节点数,  $n$  为输入层节点数,  $l$  为输出层节点数,  $a$  为 1-10 之间的随机常数.

经过大量实验最终选定 6-8-1 的网络结构, 为了加速收敛并缓解局部极小值, 这里增加冲量项对 BP 神经网络进行改进, 学习率为 0.01, 冲量 0.01, 隐层激活函数采用 sigmoid, 输出采用 purelin. 选取最后 12 组误差作为测试集, 其余为训练集, 使用 R 语言对网络进行训练拟合.

步骤三. 将步骤二中的得到的预测值进行反归一化, 将反归一化后的预测值与步骤一中的预测结果叠加进行误差修正, 如式 (5), 作为钢芯铝绞线月度需求量的预测值.

#### 4.2 实验结果及分析

实验数据来自国网辽宁省电力物资供应公司, 选取 2010 年 3 月到 2016 年 12 月期间的钢芯铝绞线月度需求量为样本, 利用 BP 神经网络误差修正的 ARIMA 模型进行预测, 并与修正前的预测值和实际的需求量对比分析, 为了让预测结果显示地更清晰, 从整个样本周期中抽取 2015 年 12 月至 2016 年 12 月区间的结果如图 6 所示, 改进前后的预测相对误差率如图 7 所示.

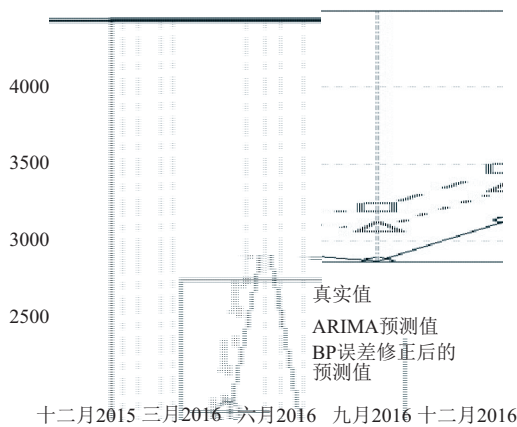


图 6 预测值和真实值拟合图 (局部)

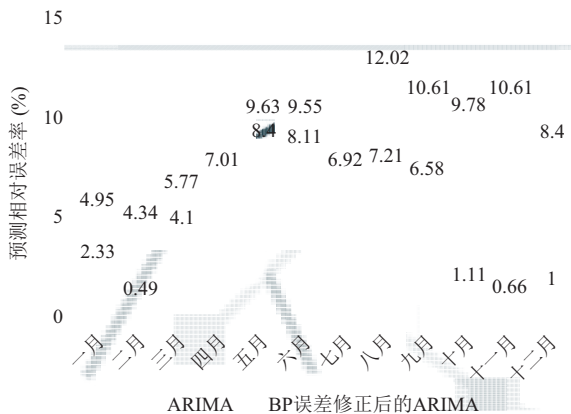


图 7 改进前后的预测相对误差率对比

从图 6 和图 7 可以看出, 经 BP 误差修正后的物资预测精度有了明显的提高, 预测结果更贴近. 在 ARIMA 模型预测误差较大的后半年, BP 误差修正的效果非常显著, 尤其是 10 至 12 月份, 修正后的预测值几乎是与真实的需求量吻合的. 从整体来看, ARIMA 模型的平均相对误差率为 7.86%, BP 修正后的平均相对误差率为 4.88%, 相对误差率降低了 2.98%, 效果显著.

电网是一个非常复杂的系统, 影响电力物资需求的因素众多, 包括季节因素、国家政策、宏观经济形势、市场因素等诸多因素, 关系异常复杂, 在建立物资需求预测模型时很难找出所有的影响因素. 电力物资月需求量的历史统计数据是所有影响因素互相作用的结果, 其中隐含包括了这些影响因素对电力物资需求影响的规律. 所以, 本文提出的预测方法是将所有外部因素对电力物资需求的影响规律作为一个复杂的、综合的规律进行表达, 而不需要人为分析影响物资需求的外部因素, 避免了因选择外部因素的不同和不全面造成的预测偏差. 在铝绞线预测中, BP 误差修正后的模型既有效刻画了序列的线性相关性, 又捕获了非线性关系, 预测结果基本上能够反映铝绞线月需求量的实际情况, 可以为制定物资采购计划提供重要的数据支持.

#### 参考文献

- 杨建国. 推行电力物资供应链管理 促进电网应急物资保障. 市场研究, 2011, (9): 52-54.
- 宋斌, 卜涛, 张洪青. 电网建设项目物资需求预测研究. 物流技术, 2013, 32(3): 319-321, 336.
- Unlu NT. Improving the Turkish navy requirements determination process: An assessment of demand forecasting methods for weapon system items. Monterey: Naval Postgraduate School, 2001.
- 宋斌, 宋秉虎, 沈男, 等. 基于 BP 神经网络的电网建设项目物资需求预测. 时代经贸, 2013, (10): 206-207.
- 韩戟, 何成浩, 苏星, 等. 一种基于 SVM 的电力行业物资需求预测方法. 电气技术, 2016, (12): 152-154. [doi: 10.3969/j.issn.1673-3800.2016.12.033]
- 李晨熙. 基于 ARIMA 模型的短期电力负荷预测. 吉林电力, 2015, 43(6): 22-24.
- 张树京, 齐立心. 时间序列分析简明教程. 北京: 清华大学出版社, 2003.
- 肖静, 邹传平, 郑冬喜. 浅谈 BP 神经网络预测模型. 科技资讯, 2006, (34): 9. [doi: 10.3969/j.issn.1672-3791.2006.34.007]
- Meng K, Dong Z Y, Wong K P. Self-adaptive radial basis function neural network for short-term electricity price forecasting. IET Generation, Transmission & Distribution, 2009, 3(4): 325-335.
- 沈男. 基于改进 BP 神经网络的电网物资需求预测研究[硕士学位论文]. 北京: 华北电力大学, 2014.
- 谢晓旭, 袁兆康. 基于 R 的江西省肺结核发病率 ARIMA-SVM 组合预测模型. 中国卫生统计, 2015, 32(1): 160-162.
- 刘夏, 陈磊, 李苑辉, 等. 基于组合方法的三亚机场客流量预测. 计算机系统应用, 2016, 25(8): 23-28. [doi: 10.15888/j.cnki.csa.005268]