

基于 MATLAB 的短时电力负荷预测方法研究

焦晶¹, 宋志刚¹, 王慧锋¹, 把明全¹, 孙诚磊¹, 宋厚彬²

(1. 国网甘肃省电力公司陇南供电公司, 甘肃 陇南 742500;

2. 兰州理工大学, 甘肃 兰州 730050)

摘要: 电力系统负荷预测在电力系统调度、用电、规划中起着至关重要的作用。通过对历史数据的分析和研究, 基于 MATLAB 软件平台对 ARMA 时间序列和 BP 神经网络两种预测方法进行了仿真实现。算例仿真结果表明, 进行短期电力负荷预测时, 时间序列法较 BP 神经网络法具有原始数据少、程序实现简单和训练时间短等优点。

关键词: 电力负荷; 短时预测; 时间序列; BP 神经网络

中图分类号: TM715 **文献标识码:** A **文章编号:** 1671-0711 (2017) 11 (下) -0063-03

电力负荷预测是电力部门的重要工作之一, 进行电力负荷精准的预测, 对于合理安排电网运行方式和机组检修计划, 节煤、节油降低发电成本, 提高系统的经济效益和社会效益有着重要意义。目前已有多种电力预测的方法, 传统方法如线性回归法、时间序列法和趋势外推法等, 新型的预测方法如人工神经网络、灰色预测和空间负荷预测、模糊负荷预测等。

本文针对 ARMA 与 BP 神经网络方法, 基于 MATLAB 建立了仿真模型。由仿真结果得到 ARMA 时间序列模型拟合效果较好、实现速度快且过程清晰。而 BP 神经网络由于学习速率是固定的, 因此网络的收敛速度慢, 需要较长的训练时间, 且需要较大规模的历史数据。

1 基于 ARMA 模型的负荷预测

时间序列是常用的传统预测方法之一, 自回归移动平均 ARMA (Auto Regressive Moving Average) 模型是时间序列分析法, 是建立在严密的数学理论基础之上。

1.1 ARMA 模型的定义

一般地, 一个 ARMA (p,q) 模型, 形如

$$y_t = \varphi_0 + \varphi_1 y_{t-1} + \dots + \varphi_p y_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \dots - \theta_q \varepsilon_{t-q} \quad (1)$$

1.2 ARMA 模型的 ACF 与 PACF

自相关函数 ACF (Auto Correlation Function) 和偏相关函数 PACF (Partial Auto Correlation Function) 是识别 ARMA 过程的重要工具, 对初步识别平稳序列的模型类型和模型阶数可以起到辅助作用。ARMA 模型在 P 阶后 ACF 与 PACF 都显示出拖尾性。

基金项目: 基金 AD 国网甘肃省电力公司陇南供电公司项目 (项目编号: H1703cc010)。

1.3 模型阶次的确定

ARMA 的定阶问题是 ARMA 模型的核心问题, 定阶的方法有很多种, 本文采用了 AIC 准则。AIC 准则即最小信息准则, 同时给出 ARMA 模型阶数和参数的最佳估计, 适用于样本数据较少的问题。具体运用时, 在规定的范围内使模型阶数由低到高, 分别计算 AIC 值, 最后确定使其值最小的阶数, 就是模型的合适阶数。

模型参数最大似然估计时:

$$AIC = (n - d) \log 2 + 2(p + q + 2) \quad (2)$$

模型参数最小二乘估计时:

$$AIC = (n - d) \log 2 + (p + q + 1) \log n \quad (3)$$

式中: n 为样本数; σ^2 为拟合残差平方和; d 、 p 、 q 为参数, p 、 q 范围上限当 n 较小时取 n 的比例, 当 n 较大时取 $\log n$ 的倍数。

2 基于 BP 神经网络的负荷预测

BP 神经网络也是一种常用的预测方法, 是一种单向传播的多层前向网络, 神经元分层排列, 分别组成输入层、中间层、和输出层, 同层之间无耦合。人工神经网络是通过模拟人脑神经网络结构、功能及信息处理机理而建立起来的网络。它具有良好的非线性关系映像能力, 并实现非线性关系的隐式表达, 具有建模简单、容错性强的优点, 比较适合对电力系统负荷预测建模。

BP 神经网络预测的实现, 其主要步骤如下。

(1) 设置网络结构, 初试化权值和阈值 θ 为较小的随机值, 使每个神经元的净输入值很小, 保证工作在激活区。

(2) 给定输入 / 输出样本对, 提供训练集合。取样本对, 分别计算隐含层和输出层各神经元的输出。

(3) 按照公式 (4) 计算网络误差, 误差值不符合预定值时按照式 (5) 和式 (6) 分别计算和, 然后调整各层神经元的连接权值和阈值。

误差函数为:

$$E_p = \frac{1}{2} \sum_{k=1}^L (d_{pk} - O_{pk})^2 \quad (4)$$

$$\Delta W_{jk} = \eta O_{pk}(1 - O_{pk})(d_{pk} - O_{pk})O_{pj} = \eta \delta_{pk} O_{pj} \quad (5)$$

$$\Delta \theta_j = \eta O_{pj}(1 - O_{pj}) \left(\sum_{k=1}^L \delta_{pk} W_{jk} \right) = \eta \delta_{pj} \quad (6)$$

返回步骤(3)重复计算,直至误差负荷预定要求为止。

3 实例分析

已知某地3月份的负荷数据,每隔2小时取一组,共372组数据。取前347组为实验数据,后24组为校验数据,完成短时预测。在建立模型前要完成数据的平稳化处理,检查负荷序列是否平稳,若不平稳,就要对序列进行差分,差分后成为平稳序列,则称其为P阶单整序列,其中P为差分的次数。然后计算平稳序列的自相关函数和偏相关函数,通过计算自相关函数和偏相关函数,确定取P=3。

可以发现自相关系数和偏相关系数均有拖尾性,所以适用ARMA模型。然后拟合做残差分析,设置信度为0.95时的自相关函数与偏相关函数曲线,利用AIC最小值确定ARMA模型,最后得到负荷预测值,预测值、实际值及误差曲线如图1所示。

BP神经网络建立,将第一周的实际负荷作为训练输入向量并对新建的BP神经网络进行训练。然后将第二周的实际负荷作为预测输入向量,初始化权值w和阈值b,即把所有权值和阈值设置成最小的随机数;设置BP人工神经网络的输入和输出层各有24个神经元,给定训练步数为1000,允许误差0.01。

由仿真结果可知,在BP神经网络中间层为68个神经元时,预测结果最好。经过相同次数训练后,网络训练误差为0.0099,并输出最后得到的负荷预测值,预测值与实际值如图2所示。

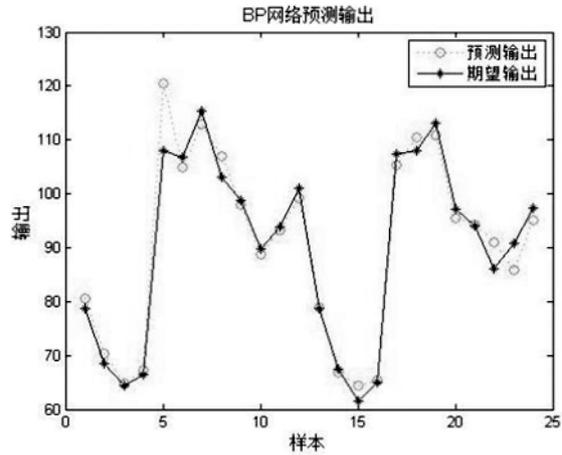


图2 BP神经网络模型预测值与实际值

由图1和图2看出,两种模型输出的预测值与实际值相比较,ARMA模型的输出值与实际值相比较拟合度较好而BP模型存在差异较大的值。两种模型输出的预测值与实际值的误差如表1所示。

表1 ARMA模型预测与BP网络预测的实际值误差

序号	实际值	ARMA模型预测		BP网络预测	
		预测值	相对误差	预测值	相对误差
1	78.801	80.95	-2.148	80.528	-2.191
2	68.571	67.61	0.961	70.391	-2.653
3	64.403	61.532	2.871	64.85	-0.692
4	66.435	68.538	-2.102	67.188	-1.132
5	108.052	107.881	0.171	114.454	-11.477
6	106.855	107.308	-0.452	105.01	1.727
7	115.406	114.258	1.148	112.987	2.096
8	103.093	99.644	3.449	106.995	-3.784
9	98.813	101.802	-2.988	97.927	0.897
10	89.732	88.401	1.331	88.858	0.974
11	93.785	94.018	-0.232	93.274	0.545
12	101.056	97.608	3.448	99.157	1.879
13	78.66	76.538	2.122	78.918	-0.327
14	67.54	65.328	2.212	66.771	1.138
15	61.594	60.287	1.307	64.348	-4.47
16	64.955	66.728	-1.772	65.334	-0.582
17	107.416	107.771	-0.354	105.313	1.958
18	107.968	107.626	0.342	110.519	-2.362
19	113.213	110.776	2.437	110.895	2.047
20	97.2402	95.712	1.528	95.505	1.784
21	94.067	93.768	0.299	94.223	-0.165
22	86.153	85.718	0.435	90.963	-5.58
23	90.779	89.648	1.131	85.965	5.303
24	97.385	95.373	2.012	95.001	2.44

由表1可知:时间序列模型在短时负荷预测实例分析中,最大误差4.459%,平均绝对值误差为1.84%,均方差为1.6,BP神经网络中最大误差11.477%,平均绝对值误差2.42%,均方差为5.87。显然BP神经网络预

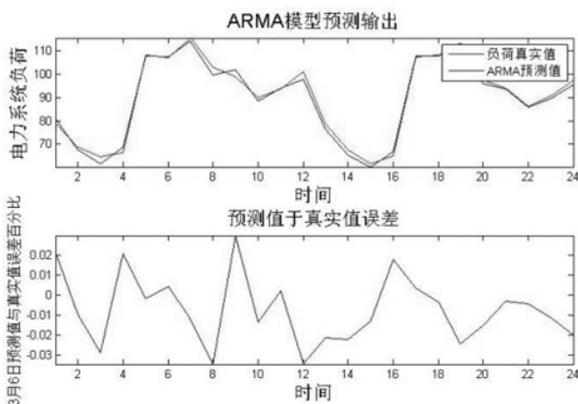


图1 ARMA模型预测值、实际值及误差曲线

RFID 在斗轮堆取料机行走距离检测上的应用

刘铁

(长春发电设备总厂, 吉林 长春 130033)

摘要: 斗轮堆取料机在轨道上的行走距离, 常规是采用光电编码器来进行检测, 由于种种原因, 经常出现累计误差, 影响检测的精度及准确性。而采用 RFID(无线射频识别)可避免以上的问题, 极大的提高斗轮堆取料机检测的精度及使用的可靠性, 并使斗轮堆取料机的日常使用和维护更加简便及省时, 是斗轮堆取料机位置检测控制技术的发展趋势。

关键词: 斗轮堆取料机; 位置检测; RFID(无线射频识别)

中图分类号: TH24 **文献标识码:** A **文章编号:** 1671-0711(2017)11(下)-0065-02

斗轮堆取料机是一种大型高效连续的散料装卸专用设备, 随着电力、港口、冶金、矿山等大型散料输送系统的迅猛发展, 斗轮堆取料机做为散料装卸机械的其中一种产品, 开始向大型化、专业化、智能化的方向发展。未来大型料场智能化无人控制将成为普遍的需求, 而斗轮堆取料机做为智能化料场中的主要设备, 其未来的发展方向是实现无人化、智能化的全自动运行。

然而, 如实现斗轮堆取料机智能化无人控制, 防止斗轮堆取料机悬臂碰撞料堆, 对斗轮堆取料机进行精确定位是一项必然的要求。一般斗轮堆取料机都是在轨道上行走, 行走距离从几十米到几百米不等, 通常检测斗轮堆取料机行走距离是采用增量型光电编码器。然而由于斗轮堆取料机检测车轮的打滑, 或是在制动时的自然滑行, 都会使编码器丢失数据, 进而产生累计误差。而采用 RFID(无线射频识别)技术可避免以上的问题, 极大的提高了斗轮堆取料机检测的精度及使用的可靠性, 并使斗轮堆取料机的日常使用和维护更加简便及省时, 是斗轮堆取料机位置检测控制技术的发展趋势。本文以江苏南通港斗轮堆取料机 RFID 检测系统的应用概况作一介绍。

测误差较大, 数据波动明显。

4 结语

本文建立了 ARMA 模型和 BP 神经网络模型, 通过算例仿真结果可知, 在两种模型预测中, ARMA 模型的拟合度好, 方法简单、实现迅速、仿真过程明确可见。在干扰条件较少的日负荷中更易于实现。BP 神经网络在历史数据量较少时不能较好拟合曲线, 存在训练时间长、收敛速度慢、可能出现过训练和训练不稳定以及稳定性不足等缺点, 这是今后需要解决的问题。

1 斗轮堆取料机行走距离采用光电编码器检测的常见问题

斗轮堆取料机行走距离通常采用增量型光电编码器来进行检测, 一般常用的是 TOYO 公司的 TRD 系列产品, 分辨率 50 脉冲/转, 带双向输出。光电编码器安装在行走车轮上, 当斗轮堆取料机在轨道上行走时, 行走车轮带动光电编码器旋转, 其发出的脉冲信号通过连接电缆, 传送到斗轮堆取料机电气系统的控制核心——可编程控制器 PLC。行走光电编码器控制系统框图如图 1 所示。

采用光电编码器进行行走距离检测常见的问题如下。

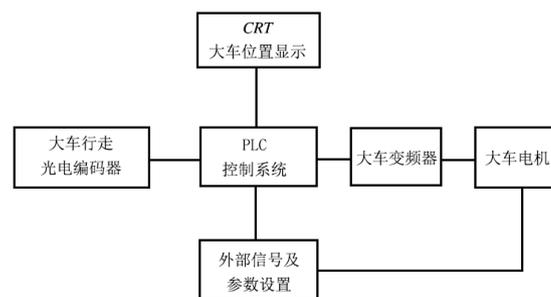


图 1

参考文献:

- [1] 陈昊. 采用现代时间序列分析方法的电力负荷预测 [M]. 北京: 中国电力出版社, 2016, 4-5.
- [2] 张善文. MATLAB 在时间序列分析中的应用 [M]. 西安: 西安电子科技大学出版社, 2007, 66-67.
- [3] 杨军祥. 三代半航空电子系统核心处理技术研究 [J]. 微电子学与计算机, 2007, 6: 45-49.
- [4] 张云歌. 电力系统的负荷预测方法研究 [J]. 工业控制计算机, 2015, 28(12): 152-154.
- [5] 何琬等. 基于深层神经网络的电力负荷预测 [J]. 环境可持续发展, 2016, 41(1): 83-87.