

文章编号:1671-6833(2013)01-0078-04

短期电力负荷组合预测方法研究

罗 勇, 郑 金, 宁美凤

(郑州大学 电气工程学院, 河南 郑州 450001)

摘 要:为了解决短期电力负荷不同预测方法的预测角度片面性、预测精度差等问题,提出了基于小波神经网络(WNN)的组合预测模型.首先用小波神经网络预测模型和历史平均模型分别进行预测,然后再通过小波神经网络对两单一模型的预测值进行组合.相比 BP 神经网络组合模型,该组合预测模型的预测精度大大提高.该模型同时引入模糊聚类分析的方法选取组合模型的训练样本,减少了训练样本的冗余性,提高了预测模型的精度.

关键词:短期电力负荷预测;组合预测;小波神经网络;模糊聚类分析

中图分类号: TM76

文献标志码: A

doi:10.3969/j.issn.1671-6833.2013.01.019

0 引言

目前国内外学者对短期电力负荷预测进行了许多研究.研究方法大致可以分为两大类:一种是传统统计分析方法^[1-2];另一种是现代预测方法^[3-4].但是客观条件不断变化,单一预测模型不能在复杂多变的情况下保持良好的预测性能.为了解决上述问题,组合预测方法应运而生,它综合各种单项预测方法优点,在一定程度上改善了预测精度^[5].神经网络是变权重组合预测的重要方法.基于神经网络组合预测方法比其他的组合预测方法预测精度有了明显的提高^[6-7].但是 BP 神经网络训练过程中,具有收敛速度慢、易陷入局部极小值等缺点.因此,笔者建立了基于小波神经网络的短期电力负荷组合预测模型.

1 小波神经网络

小波神经网络^[8]是在小波分析基础上,采用小波元取代神经元,即用非线性小波函数取代 Sigmoid 函数作为激活函数,应用于函数逼近.

小波神经网络输入层有 n 个神经元,用 x_k 表示输入层的第 k 个神经元输入量;小波变换层有 m 个神经元, x'_i, y'_i 分别表示该层第 i 个神经元的输入量与输出量.

$$x'_i = \sum_{k=1}^n w_{ki} x_k; \quad (1)$$

$$y'_i = \psi_{a,b}(x'_i). \quad (2)$$

式中: $\psi_{a,b}$ 为小波变换函数; w_{ki} 为输入层与小波层之间的连接权值.输出层有一个神经元,输出值 Y_q 为

$$Y_q = g\left(\sum_{j=1}^m w_j y'_i\right). \quad (3)$$

式中: w_j 为小波层与输出层之间的连接权值.

小波函数的种类有很多种,为了运算的方便性,此处选取 Morlet 小波.因此小波层的变换基函数为

$$\psi_{a,b} = \cos(5x_p) \cdot \exp(-x_p^2/2). \quad (4)$$

式中: $x_p = (x - a_i)/b_i$, b_i 为小波神经元 i 的伸缩系数,而 a_i 为小波神经元 i 的平移系数.

小波神经网络的结构可以用以下式子表示:

$$Y_q = g\left(\sum_{j=1}^m w_j \psi_{a,b}\right). \quad (5)$$

式中: a_i 和 b_i 通过神经元学习算法进行修正,参数 w_j, w_{ki} 通过最小误差能量函数进行优化.

为了简单方便,令 $g(x) = x$ 得到下式:

$$E_q = \frac{1}{2} \sum_{h=1}^N [Y_q(t) - \bar{Y}_{sq}(t)]^2 \\ = \frac{1}{2} \sum_{h=1}^N \left[\sum_{j=1}^m w_j \psi_{a,b} - \bar{Y}_{sq}(t) \right]^2. \quad (6)$$

收稿日期:2012-10-27;修订日期:2012-12-21

基金项目:河南省科技攻关计划资助重点项目(112102210100)

作者简介:罗勇(1977-),男,湖南桃源人,郑州大学副教授,博士,主要研究模式识别与智能系统、电力系统负荷预测、智能传感器和仪器仪表等. E-mail: luoyong@zzu.edu.cn.

式中: N 表示训练样本数; $\bar{Y}_{sq}(t)$ 表示第 s 个样本的第 q 个期望值。

采用梯度下降法作为小波神经网络的学习法则. 根据式(6)得到 E_q 的负梯度值, 由此获得该网络中每个参数有关的局部误差函数. 再根据局部误差函数构造出梯度矢量, 小波神经网络中的每个参数可以用梯度下降法确定。

2 组合预测模型

为了克服 BP 算法收敛速度慢, 易于陷入局部极小值等缺点. 用小波神经网络作为组合模型, 模型输入层有两个神经元, 输入量分别是小波神经网络预测模型和历史平均模型(一次指数平滑法)两种单一模型的预测值. 输出层有一个神经元, 在训练过程中输出值为实际电力负荷量, 而在预测的过程中输出量为组合模型的总输出值, 而隐含层有 5 个神经元. 小波神经网络组合模型的结构图如图 1 所示。




图 1 小波神经网络求和模型的结构图

Fig. 1 The structure of summation wavelet neural network

2.1 模糊聚类分析

为了减少天气、星期类型等多种因素对电力负荷序列变化的影响, 笔者应用模糊聚类分析方法, 从历史数据中选取与待预测日的特征集最为接近的历史日数据作为训练样本。

对电力负荷变化影响的各种因素中, 星期类型、温度和降水量对负荷影响较大. 应用模糊聚类分析方法对短期电力负荷预测模型的训练样本进行分类. 设特征总数为 M , 样本总数是 N , 第 n 个样本的第 m 个特征量表示为 x_{nm} , 构成原始样本矩阵。

采用相关系数法, 建立模糊相似矩阵 R , 表达式如下:

$$r_{nm} = \frac{\sum_{k=1}^M x_{nk} x_{mk}}{\sqrt{\sum_{k=1}^M x_{nk}^2} \sqrt{\sum_{k=1}^M x_{mk}^2}} \quad (7)$$

模糊相似矩阵 R 通过不断地自乘, 直到出现 $R^{2^T} = R^T$ 时 (T 为指数), R^T 便是一个模糊等价关系矩阵, 并且满足自反性、对称性和传递性, 因此可以用来对样本进行聚类。

分类的结果与 λ 有关, λ 取值越大, 分的类数越多. 根据实际的需要选定适当的 λ 值, 即可利用上一步求得的模糊等价关系矩阵对 N 个不同训练样本进行分类。

最后以预测日的特征为新的样本, 将该样本的特征首先进行数值化, 然后再进行模糊聚类, 确定预测日属于以上哪一类. 具体聚类结果见第 3 节实例分析。

2.2 基于小波神经网络的组合预测模型

通过上述模糊聚类分析, 从电力负荷序列原始样本中选取与待预测日特征相似日期的数据做为组合预测模型的训练样本. 模糊聚类分析获得与预测日相类似的 $(m+n)$ 个电力负荷序列样本, 其中 n 个样本用来训练小波神经网络模型, 确定其参数. 其他 m 个样本作为组合模型的训练样本. 通过如第 1 节叙述的训练过程获得小波神经网络组合模型的结构参数, 其过程如图 2 所示。




图 2 组合预测模型结构参数获得过程图

Fig. 2 The acquisition process of combination forecasting model structure parameters

3 实例分析

笔者以河南某市的电力负荷为研究对象, 比较各个预测模型的预测精度. 选取 2011 年 7 月 1 日至 7 月 31 日, 每天从 0 点到 23 点的整点时刻电力负荷量, 共获得 744 个样本值, 并记录这 31 d 当地天气状况(最高气温、最低气温和降水量)、星期类型. 而 2011 年 8 月 1 日特征为周一、平均最高气温 32℃、平均最低气温 22℃、平均降水量 4 mm。

步骤一: 根据特征: 星期、温度和降水量可以将所选取 31 d 进行列表, 特征列表如表 1 所示。

在模糊聚类分析过程中, 选择 λ 值为 0.975 6, 把 31 组数据分成 5 类. 把 8 月 1 日的特征数据化, 再进行模糊聚类得到该日属于类 3, 类 3 具体包括 {3 号, 4 号, 10 号, 11 号, 17 号, 18 号, 24 号,

表 1 31 d 的特征值

Tab.1 The features list of 31 days

日期	1 号	2 号	3 号	4 号	5 号	26 号	27 号	28 号	29 号	30 号	31 号
平均最高气温	32	32	31	31	31	32	33	32	32	32	32
平均最低气温	22	22	22	22	22	23	23	24	24	23	23
平均降水量	4	9	7	4	5	5	6	3	9	6	8
星期	4	5	6	7	1	1	2	3	4	5	6

25 号,31 号}. 然后从类 3 集合中随机选取 3 号, 10 号,11 号,17 号,24 号,25 号 6 d 144 个训练样本用于训练.

步骤二:首先利用步骤一获得的训练样本,对小波神经网络预测模型进行训练,其结构为 4-8-1. 然后分别利用小波神经网络和一次指数平滑模型,对 8 月 1 日内的 24 h 的电力负荷进行预测. 一次指数平滑法平滑系数 $\alpha = 0.8$ 时实验效果好.

步骤三:利用步骤一获得样本,作为组合预测模型的训练样本. 测试结果显示,模型有较好的精确度. 然后用步骤二两组 8 月 1 日预测值输入到小波神经网络组合模型中,获得该日的组合预测值,如图 3 所示.

步骤四:为了便于比较,利用 BP 神经网络对两种单一预测模型进行组合,获得 8 月 1 日预测结果,如图 3 所示. 并通过求得出两种组合预测方法的误差比较,如表 2 所示.




图 3 电力负荷实际值与预测值

Fig.3 Contrast of forecasting results and real power load

通过图 3 与表 2 对比可得出:基于 BP 神经网络的组合预测模型,可能由于容易陷入局部最优等问题,而使得预测结果较差. 而基于 WNN 组合预测模型克服了 BP 神经网络缺点,预测结果更接近实际数据.

表 2 预测方法误差对比

Tab.2 Error contrast of forecasting methods

误差类别	BP 神经网络 组合预测模型	WNN 组合 预测模型
平均绝对 值误差/MkW	1 127	508.9
平均绝对 百分比误差/%	3.43	1.43

4 结论

笔者利用模糊聚类分析方法选取预测模型的训练样本,以此训练两个小波神经网络,大大减小了小波神经网络训练时间,并且增强了组合模型训练的针对性. 小波神经网络克服了 BP 神经网络易于陷入局部最优等缺点,提高了组合模型的精度. 但是,这种组合预测模型也存在一定缺点,如两个网络分别训练,运算量较大,时间较长. 而寻找其他智能调节权重的方法,缩短整个模型的训练时间将是未来研究的主要方向.

参考文献:

[1] 沈辉,胡德文. 基于正交最小二乘估计的非线性时间序列的预测[J]. 国防科技大学学报,2001,23(2):115-118.

[2] CONTRERAS J, FRANCISCO J. ARIMA models to predict next day electricity prices[J]. IEEE Transactions on Power Systems,2003,18(3):1014-1020.

[3] MANDAL P, SENJYU T, URASAKI N, et al. A neural network based on several-hour-ahead electric load forecasting using similardays approach[J]. Electrical Power&Energy Systems,2006,28:367-373.

[4] AMJADY N, KEYNIA F. Short-term load forecasting of power syserms by combination of wavelet transform and neuro-evolutio-nary algorithm[J]. Energy,2009,34:46-57.

[5] 方鸽飞,胡长洪,郑奕辉,等. 考虑夏季气象因素的短期负荷预测方法研究[J]. 电力系统保护与控制,2010,38(22):100-104.

[6] 姜晨,徐宗昌,肖国军. 用神经网络组合预测法估计

- 反舰导弹研制费用[J]. 系统工程与电子技术, (17):94-97.
2004,26(3):348-349. [8] 张步涵,赵剑剑,刘小华,等. 一种基于小波神经元的短期负荷预测方法[J]. 电网技术,2004,28(7):15-18.
- [7] 李蔚,盛德仁. 双重 BP 神经网络组合模型在实时数据预测中的应用[J]. 中国电机工程学报,2007,27

Short-term Power Load Combination Forecasting Method

LUO Yong, ZHENG Jin, NING Mei-feng

(School of Electrical Engineering, Zhengzhou University, Zhengzhou 450001, China)

Abstract: In order to solve the defect and the poor prediction accuracy of different prediction methods in short-term power load forecasting, the combination forecasting method based on wavelet neural network is proposed. First, the wavelet neural network prediction model and the historical average model are used to predict respectively. Then, the predicted views of the two models are combined by wavelet neural network. Compared with BP neural networks combination model, the prediction accuracy of this combination forecasting model is improved greatly. Fuzzy clustering analysis method is utilized in this paper to select training samples of the combined model, the training sample redundancy is reduced and the prediction accuracy is improved.

Key words: short-term electric power load forecasting; combination forecasting; wavelet neural network; fuzzy cluster analysis

(上接第 77 页)

- [4] 袁峰,王太勇,聂惠娟. 基于创新设计理论/功能分析的机械产品功能原理创新设计[J]. 计算机集成制造系统,2006,12(2):204-209. [7] ALTSHULLER G S. Suddenly the Inventor Appeared [M]. USA: Technical Innovation Center, 1996.
- [5] 林岳,徐燕申,牛占文. 基于物-场分析法的机械产品创新[J]. 天津大学学报,2001,34(1):99-102. [8] 高常青. TRIZ-发明问题解决理论[M]. 北京:科学出版社,2011.
- [6] 檀润华. 发明问题解决理论[M]. 北京:科学出版

Design and Research for the Layout of Spin Riveting Machine Based on Substance-field Analysis

YUAN Feng¹, DING Ze-xin¹, LI Yue-mei², ZHU Jun¹

(1. School of Mechanical Engineering, Zhengzhou University, Zhengzhou 450001, China; 2. Tangshan Jidong Petroleum Mechanical Co., LTD, Tangshan 063200, China)

Abstract: Based on substance-field analysis theory, firstly, the design conflicts are described, according to the actual demands of design for the layout of Spin Riveting Machine in the automatic assembly system of saw chain. Secondly, substance-field model of chain shaft riveting is set up. Finally, the design space conflicts are solved by using the 76 standard solutions and the final ideal solution of the layout of Spin Riveting Machine is found out, which reduces the whole system's research and development time. In a word, the successful trial of automatic assembly system of saw chain will greatly enhance saw chain's assembly efficiency and quality, reducing its production cost and prolonging its using life effectively, so it is important to the technology progress of enterprises.

Key words: saw chain; the layout of Spin Riveting Machine; substance-field model; TRIZ