基于证据理论加权的电力负荷组合预测

为了提高电力负荷的预测准确度，提出了一种基于证据理论加权的电力负荷组合预测模型。首先分别采用自回归移动平均模型、灰色模型和BP神经网络对电力负荷进行预测，分别得到电力负荷的线性、周期性和非线性预测结果；然后采用证据理论确定自回归移动平均模型、灰色模型和BP神经网络的预测权值；最后进行加权得到电力负荷的预测结果，并将该模型应用于具体的电力负荷建模与预测中。实验结果表明，该模型可以描述各单一模型对电力负荷预测结果的贡献，更加准确地描述电力负荷的变化特点，预测准确度能够满足实际应用的要求。

李　娜　赵建东/青岛黄海学院实践教学部

李　娜/讲师

关键词/Keywords
电力负荷·
自回归移动平均模型·
证据理论·
模型加权·

随着我国经济的快速发展，人们用电量急剧增加，而负荷预测有利于电力调度，同时可以提高电能质量，保证电力系统的安全运行，因此电力负荷预测一直是人们关注的焦点[1]。

长期以来，众多学者对电力负荷预测展开了大量的研究，取得了丰硕的研究成果。传统方法主要有回归分析法、时间序列法等[2-3]，由于电力负荷受到温度、天气状况等因素综合作用，具有周期性和混沌性等变化趋势，传统方法忽略了电力负荷预测变化的复杂性，简化了电力负荷变化的数学模型，预测结果并不理想[4]。随后，针对电力负荷变化的非线性，一些学者将人工智能算法、机器学习算法[5-7]引入到电力负荷建模与预测中，因此电力负荷的预测准确度得到了提升。在实际应用中，人工智能算法、机器学习算法是一类非线性建模方法，其难以对电力负荷周期性和规律性进行描述，预测结果与人们实际要求有一定的差距[8]。近些年，一些学者根据组合优化理论建立了电力负荷组合预测模型，如将灰色模型与神经网络结合、小波分析与支持向量机结合等，它们可以从不同方面对电力负荷信息进行描述，更准确地反映了电力负荷的变化特点，克服了单一模型只能描述片段信息的缺陷[9-10]。在组合模型建模过程中，当前采用平均方式计算单一模型预测结果的权值。从而估计它们对电力负荷预测结果的贡献，这与实际情况并不相符[11]。

为了提高负荷预测的准确性，针对单一模型权值的选择问题，提出一种基于证据理论的电力负荷组合预测模型，通过证据理论确定单一模型的最合适权值。实验结果表明，本文模型可以应用于电力负荷预测中，获得了高准确度的预测结果。

基于证据理论的负荷预测模型工作原理

针对单一模型只能描述电力负荷单一变化特性的不足，提出一种基于证据理论的电力负荷预测组合模型，其工作原理为：首先收集电力负荷样本，并采用自回归移动平均模型、灰色模型和BP神经网络分别对电力负荷的线性、周期性和非线性变化规律进行建模；然后采用证据理论确定自回归移动平均模型、灰色模型和BP神经网络的权值；最后通过权值得到电力负荷的预测结果，具体如图1所示。

相关模型

1. 自回归移动平均模型

自回归移动平均模型（ARIMA）可

(C)1994-2023 China Academic Journal Electronic Publishing House. All rights reserved.　http://www.cnki.net

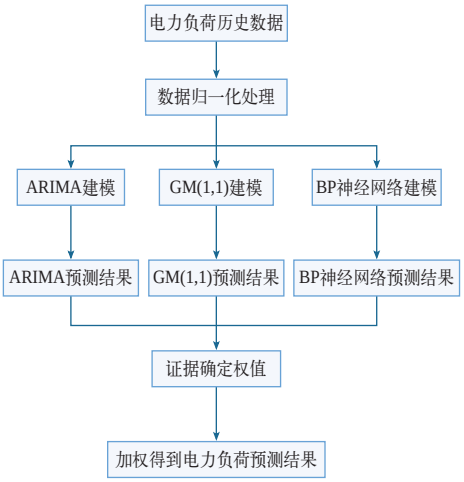

图1　基于证据理论的电力负荷预测模型工作原理

表示为

$$\begin{aligned} y(t)&=v+\varphi_1 y(t-1)+\cdots+\varphi_p y(t-p)+\varepsilon(t)\\ &=v+\varphi_1 y(t-1)+\cdots+\varphi_p y(t-p)+a(t)+\\ &\quad \Theta_1 a(t-1)+\cdots+\Theta_p a(t-q)\end{aligned} \tag{1}$$

可以得到ARIMA(p,q)的等价模型为

$$y(t)=v+\sum_{i=1}^{n}\varphi_i y(t-i)+a_n(t) \tag{2}$$

式中，$a_n(t)$为误差项。

$\hat{a}_n(t)$的计算公式为

$$\hat{a}_n(t)=y_t+\sum_{i=1}^{n}\hat{\varphi}_i y(t-i)-v \tag{3}$$

式中，$\hat{\varphi}_i$通过LS获得。

通过$\hat{a}_n(t)$可建立电力负荷的ARIMA(p,q)，即

$$y(t)=[v,\varphi_1,\cdots,\varphi_q:\Theta_1,\cdots,\Theta_q]\begin{pmatrix}1\\ y(t-1)\\ \vdots\\ \hat{a}_n(t-1)\\ \vdots\\ \hat{a}_n(t-q)\end{pmatrix}+a(t) \tag{4}$$

估计ARIMA模型的参数n、p和q。

$$AIC(p,q)=\ln\left|\hat{\Sigma}_a(p,q)\right|+\frac{2}{S}P_{\text{num}} \tag{5}$$

2. 灰色模型

1）收集电力负荷的历史样本为

$$X^{(0)}=[x^{(0)}(1),x^{(0)}(2),\cdots,x^{(0)}(n)] \tag{6}$$

2）对原始电力负荷样本进行累加，得到

$$X^{(1)}=[x^{(1)}(1),x^{(1)}(2),\cdots,x^{(1)}(n)] \tag{7}$$

3）构造矩阵$\boldsymbol{B}$与向量$\boldsymbol{Y}_n$

$$\boldsymbol{B}=\begin{pmatrix}-\left(x^{(0)}(2)+x^{(0)}(1)\right)/2 & 1\\ -\left(x^{(0)}(3)+x^{(0)}(2)\right)/2 & 1\\ \vdots & \vdots\\ -\left(x^{(0)}(n)+x^{(0)}(n-1)\right)/2 & 1\end{pmatrix} \tag{8}$$

$$\boldsymbol{Y}_n=\left(x^{(0)}(2),x^{(0)}(3),\cdots,x^{(0)}(n)\right)$$

4）采用最小二乘法求解系数$\hat{a}$，即$\hat{a}=(\boldsymbol{B}^{\mathrm{T}}\boldsymbol{B})^{-1}\boldsymbol{B}^{\mathrm{T}}\boldsymbol{Y}_n$，得到原始电力负荷样本的响应函数为

$$\hat{x}^{(1)}(k+1)=\left(x^{(0)}(1)-b/a\right)\mathrm{e}^{-ak}+b/a \tag{9}$$

5）对原始电力负荷样本预测结果$\hat{x}^{(1)}(k+1)$做“累减”，得到原始电力负荷样本的预测值为

$$\hat{x}^{(0)}(k+1)=\hat{x}^{(1)}(k+1)-\hat{x}^{(1)}(k) \tag{10}$$

3. BP神经网络

设BP神经网络的输入层、隐含层和输出层节点数分别为I、H和O，样本数为P，那么隐含层第j个节点的输入为

$$\text{net}_j=\sum_{i=1}^{I}\frac{(w_{ij}x_i-b_j)}{a_j} \tag{11}$$

输出层第k个节点的输出为

$$O_k=w_{jk}f\{\sum_{j=1}^{H}w_{ij}[\Psi_{a,b}(\text{net}_j)+\delta_j]\}+\delta_k \tag{12}$$

式中，δ_j和δ_k分别为隐含层和输出层阈值。

采有梯度下降算法确定神经网络的参数，具体如下

$$\frac{\partial E}{\partial w_{jk}}=\sum_{p=1}^{P}(d_k-O_k)O_k(1-O_k)y_j \tag{13}$$

$$\frac{\partial E}{\partial w_{jk}}=\sum_{p=1}^{P}\left(\sum_{k=1}^{O}(d_k-O_k)O_k(1-O_k)w_{jk}\right)\frac{\Psi'_{a,b}(\text{net}_j)}{a_j}x_i \tag{14}$$

$$\frac{\partial E}{\partial \delta_k}=\sum_{p=1}^{P}(d_k-O_k)O_k(1-O_k) \tag{15}$$

$$\frac{\partial E}{\partial \delta_j}=\sum_{p=1}^{P}\left(\sum_{k=1}^{O}(d_k-O_k)O_k(1-O_k)w_{jk}\right)\frac{\Psi'_{a,b}(\text{net}_j)}{a_j} \tag{16}$$

$$\frac{\partial E}{\partial b_j}=-\sum_{p=1}^{P}\left(\sum_{k=1}^{O}(d_k-O_k)O_k(1-O_k)w_{jk}\right)\frac{\Psi'_{a,b}(\text{net}_j)}{a_j} \tag{17}$$

$$\frac{\partial E}{\partial a_j}=-\sum_{p=1}^{P}\left(\sum_{k=1}^{O}(d_k-O_k)O_k(1-O_k)w_{jk}\right)\frac{\Psi'_{a,b}(\text{net}_j)}{a_j}\text{net}_j \tag{18}$$

修改BP神经网络的权值、阈值，即有

(C)1994-2023 China Academic Journal Electronic Publishing House. All rights reserved.　http://www.cnki.net

$$\Delta w_{jk}(t+1)=(1-mc)\eta\frac{\partial E}{\partial w_{jk}}+mc\Delta w_{jk}(t) \quad (19)$$

$$\Delta w_{ij}(t+1)=(1-mc)\eta\frac{\partial E}{\partial w_{ij}}+mc\Delta w_{ij}(t) \quad (20)$$

$$\Delta \delta_{k}(t+1)=(1-mc)\eta\frac{\partial E}{\partial \delta_{k}}+mc\Delta \delta_{k}(t) \quad (21)$$

$$\Delta \delta_{j}(t+1)=(1-mc)\eta\frac{\partial E}{\partial \delta_{j}}+mc\Delta \delta_{j}(t) \quad (22)$$

$$\Delta b_{j}(t+1)=(1-mc)\eta\frac{\partial E}{\partial b_{j}}+mc\Delta b_{j}(t) \quad (23)$$

$$\Delta a_{j}(t+1)=(1-mc)\eta\frac{\partial E}{\partial a_{j}}+mc\Delta a_{j}(t) \quad (24)$$

式中，Δw为权值增量；E为误差函数；mc为动量因子。

4. 证据理论

设m_1，m_2，…，m_n是检测框架Θ上不同证据的BPA，则其正交和$m=m_1\oplus m_2\oplus\cdots\oplus m_n$可确定为

$$m(A)=\frac{\sum_{B\cap A_i=A}\sum_{j=1}m_j(A_i)}{1-\sum_{B\cap A_i=\varnothing}\sum_{j=1}m_j(A_i)} \quad (25)$$

组合模型的电力负荷预测步骤

设电力负荷历史数据为$\{y_i\}$，$i=1,2,\cdots,n$，那么可以描述为

$$y_i=l_i+m_i+n_i \quad (26)$$

式中，l_i为线性变化部分；m_i为周期性变化部分；n_i为非线性变化部分。

本文模型的电力负荷预测步骤如下：

1）收集电力负荷历史数据为$\{y_i\}$，$i=1,2,\cdots,n$，并进行相应的预处理，表达式为

$$y_i'=\frac{y_i-x_{\min}}{x_{\max}-x_{\min}} \quad (27)$$

2）采用ARIMA对电力负荷线性变化部分进行建模，得到电力负荷线性变化部分预测结果l_i'。

3）采用GM对电力负荷周期性变化部分进行建模，得到电力负荷周期性变化部分预测结果m_i'。

4）采用BP神经网络对电力负荷非线性变化部分进行建模，得到电力负荷非线性变化部分预测结果n_i'。

5）采用证据理论确定ARIMA、GM和BP神经网络的权值，分别为r_1、r_2和r_3。

6）根据式（28）得到电力负荷的最终预测结果，即

$$y_i=r_1l_i+r_2m_i+r_3n_i \quad (28)$$

组合模型在电力负荷预测中的应用研究

1. 数据来源

采用某地区的电力负荷作为测试对象，其变化曲线如图2所示。由图2可知，采集的电力负荷具有线性、周期性和非线性变化特点。选择最后100个样本作为验证样本以测试组合模型的泛化性能，其他样本作为测试样本。

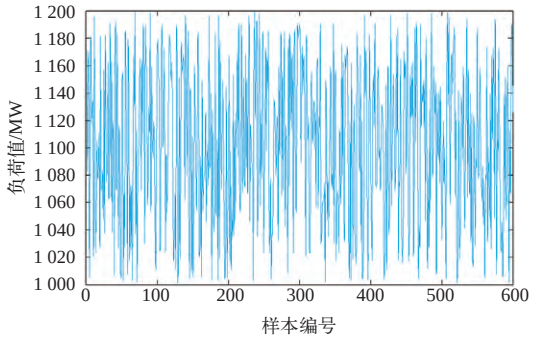

图2 收集的电力负荷数据

2. 实验结果

（1）ARIMA的预测结果

将图2电力负荷训练集输入到ARIMA进行参数估计，得到电力负荷预测模型为ARIMA(3,2,3)。采用ARIMA(3,2,3)对电力负荷的验证样本进行预测，验证样本的预测结果如图3所示。对图3进行分析可知，ARIMA(3,2,3)的预测结果不太理想，只能对电力负荷线性的变化特点进行建模，无法

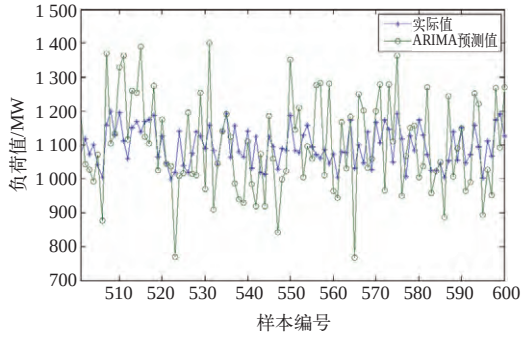

图3 ARIMA的电力负荷预测结果

(C)1994-2023 China Academic Journal Electronic Publishing House. All rights reserved. http://www.cnki.net

对其他变化特点进行准确建模，预测值与实际的电力负荷值误差较大，误差范围超过了实际应用的要求。

（2）GM的预测结果

将图2的电力负荷训练集输入到GM(1,1)进行训练，建立基于GM(1,1)的电力负荷预测模型，并对电力负荷的验证样本进行预测，验证样本预测值与预测变化曲线如图4所示。对图4进行分析可知，GM(1,1)的预测值与实际值的变化趋势相似，但是由于其只能描述电力负荷周期性的变化特点，无法对非线性变化特点进行拟合，预测准确度仍然不够准确，误差比较大。

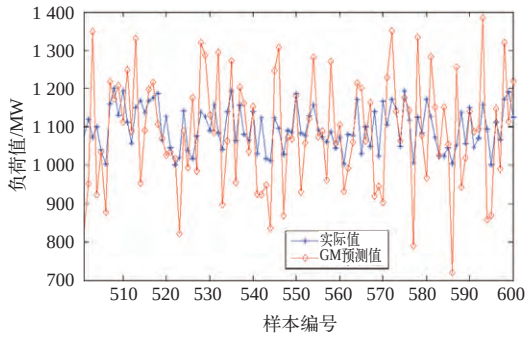

图4　GM(1,1)的电力负荷预测结果

（3）BP神经网络的预测结果

BP神经网络对电力负荷的验证样本进行预测，得到的结果如图5所示。从图5可以看出，相对于ARIMA(3,2,3)和GM(1,1)，BP神经网络的预测结果更优，预测误差相对减小，但是由于BP神经网络不能对电力负荷的线性、周期性变化特点进行描述，有极少数点的预测误差比较大。

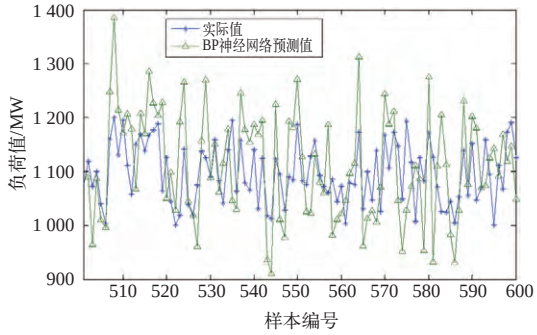

图5　BP的电力负荷预测结果

（4）组合模型的预测结果

采用证据理论确定ARIMA、GM和BP神经网络的权值，分别为$r_1=0.22$、$r_2=0.23$和$r_3=0.55$，从而得到组合模型的电力负荷预测结果，具体如图6所示。从图6可知，相对于ARIMA、GM和BP神经网络，组合模型的电力负荷预测性能得到了明显的提高，这主要是由于组合模型包括了ARIMA、GM和BP神经网络的线性、周期性和非线性预测优点，提供了更多的电力负荷信息，建立了准确度更高的电力负荷预测模型，实验结果证明了本文组合模型的优越性。

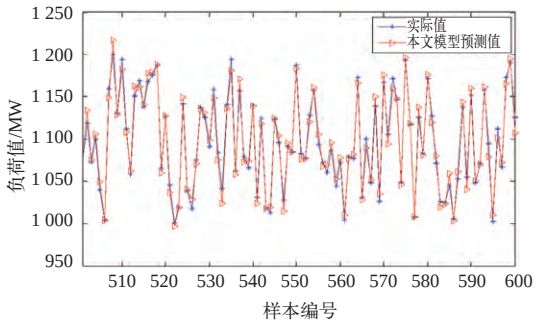

图6　给合模型的电力负荷预测结果

结束语

电力负荷具有线性、周期性和非线性等变化特点，当前组合模型认为单一模型对预测结果作用相同，难以描述负荷的实际变化规律，为此，本文提出一种基于证据理论的电力负荷预测模型，通过证据理论估计最合理的单一模型权值，实验结果表明，基于证据理论的电力负荷预测模型可以准确地描述单一模型对电力负荷预测结果的作用，电力负荷的预测准确度更高，预测结果具有一定的理论和实际意义。

参考文献

[1] 康重庆，夏清，张伯明．电力系统负荷预测研究综述与发展方向的探讨 [J]．电力系统自动化，2004，28 (17)：1-11．

[2] 郑文琛，吉培荣，罗贤举．改进无偏GM（1，1）模型及其在中长期电力负荷预测中的应用 [J]．继电器，2008，36 (5)：36-44．

[3] 王勇，黄国兴，彭道刚．带反馈的多元线性回归法在电力负荷预测中的应用 [J]．计算机应用与软

(下转第60页)

(C)1994-2023 China Academic Journal Electronic Publishing House. All rights reserved.　http://www.cnki.net

图6 调试过程中的新信号转换箱

备改造具有很好的借鉴意义。既要满足当前的现实需要，也要兼顾未来的维护和升级，这是此次直梯信号改造项目的一个基本出发点。重新仿制一个类似的信号转换板是满足当前需要的一个最为简单的办法，但对于将来的维护不利。新研制的信号处理采集卡既可采集非标信号，又可提供Modbus等通信接口；使用带控制功能的显示屏，既能够让操作员直观地看到处理前后的状态信息，也给更进一步的功能完善提供了可能[6]。大量使用现有的主流设备，除了质量能够得到保证之外，也可以避免将来的备件采购问题。

该改造项目已经顺利完成，信号转换设备也持续正常工作，但对于旧信号处理板的“黑盒”式的分析方式，始终是一种当时条件下的应急之举。获得完整的原始信号说明文件，并据此来完善触摸屏中的程序才能从根本上消除隐患。

参考文献

[1] 王静宜，靳鸿．基于PCI总线的微弱信号采集模块设计 [J]．电子世界，2013 (20)：126-127．

[2] 罗伟，朱若寒．CAN总线智能信号采集模块的设计与实现 [J]．舰船电子工程，2012 (10)：102-104．

[3] 刘俊，柳春图，李颖红，等．新一代工控组态软件MCGS及应用 [J]．新技术新工艺，2000 (6)：45-48．

[4] 吴其洲．MCGS组态软件在电梯控制系统中的应用 [J]．机械工程与自动化，2006 (4)：113-115．

[5] 于淼，郑楠，闫丰．基于MCGS与DSP的串行通信研究与实现 [J]．现代电子技术，2013 (4)：36-39．

[6] 郝继业，崔道明，黄春元．电梯控制系统的信号反馈问题 [J]．煤炭技术，2004 (10)：19-20．

（收稿日期：2015－05－13）EA

(上接第51页)

件，2008，25 (1)：83-84．

[4] 穆钢，侯凯元，杨右虹，等．负荷预报中负荷规律性评价方法的研究 [J]．中国电机工程学报，2001，21 (10)：96-101．

[5] 宁卜．基于模糊聚类分析与最小二乘支持向量机的电力负荷预测 [D]．西安：西安理工大学，2009．

[6] 唐杰明，刘俊勇，刘友波．基于最优 FCM 聚类和最小二乘支持向量回归的短期电力负荷预测 [J]．现代电力，2009，25 (2)：76-81．

[7] Zhang Yun，Zhou Quan，Sun Caixin，et al．RBF neural network and ANFIS-based short-term load forecasting approach in real-time price environment [J]．IEEE Transactions on Power Systems，2008，23 (3)：853-858．

[8] 朱继萍，戴军．中长期电力负荷预测相关影响因素优化选择 [J]．计算机仿真，2008，25 (5)：226-229．

[9] Ying Chen，Luh P B，Che Guan，et al．Short-term load forecasting：similar day-based wavelet neural networks [J]．IEEE Transactions on Power Systems，2010，25 (1)：322-330．

[10] 刘学琴，吴耀华，崔宝华．小波软阈值去噪和GRNN 网络在月度负荷预测中的应用 [J]．电力系统保护与控制，2009，37 (14)：59-62．

[11] 王继选，刘小贞，韩中合．基于多约束条件的电力负荷预测模型的研究 [J]．华东电力，2013，41 (3)：643-645．

[12] 曾鸣，冯义，刘达．基于证据理论的多模型组合电价预测 [J]．中国电机工程学报，2008，28 (6)：84-89．

（收稿日期：2015－04－22）EA

(C)1994-2023 China Academic Journal Electronic Publishing House. All rights reserved. http://www.cnki.net