

基于线性模型与非线性模型相融合的负荷预测研究

为了提高电力负荷的预测准确度，提出了基于线性模型与非线性模型相融合的负荷组合预测模型。首先采用自回归移动平均模型对电力负荷的变化趋势进行建模；然后采用极限学习机对自回归移动平均模型的电力负荷预测结果进行修正，以提高电力负荷的预测准确度；最后采用仿真实验对模型性能进行测试。测试结果表明，该模型显著地提高了电力负荷预测准确度，可为电力管理部门提供有价值的参考意见。

李伟峰/河南机电高等专科学校电气工程系



李伟峰/讲师

随着电力系统数据采集与监控技术的发展，采集的负荷数据越来越多，如何对这些数据包含的有效信息进行挖掘以及提高电力负荷预测的准确性，已成为电力系统研究领域的一个热点问题^[1]。

传统方法主要有多元线性回归分析、自回归移动平均模型等^[2]。多元线性回归方法根据电力负荷历史数据进行分析，得到指标与电力负荷之间的映射关系，同时对负荷的变化趋势进行预测，建模效率高，而且很容易实现，在电力负荷预测发展过程中起着重要作用；然而其要求电力负荷历史数据数量多，而且认为各种指标与电力负荷之间是一种线性映射关系，这违背了实际电力负荷变化的特点，预测准确度比较低^[3]。自回归移动平均模型可以对数据隐藏的信息进行挖掘，将电力负荷的变化过程当作一个时间序列，比多元线性回归分析方法的预测准确度要高，但是其只能预测具有增长趋势的电力负荷，因此应用范围受到一定的限制。近年来，一些学者将神经网络和支持向量机等^[4]非线性学习算法

引入到电力负荷建模与预测中，由于电力负荷变化是一个受诸多因素影响的非线性变化过程，其中神经网络非线性拟合能力较优，预测准确度较高，在电力负荷预测过程中应用较广。电力负荷变化具有非常复杂的非线性、趋势性和随机性，然而目前还没有一种通用的电力负荷预测方法能对所有负荷具有较好的预测结果，为此有学者提出采用组合优化理论对电力负荷进行建模与预测，克服单一模型的不足，提高电力负荷的预测准确度，这成为当前电力负荷建模与预测的主要研究方向。

为了提高电力负荷的预测准确度，融合自回归移动平均（ARMA）模型和极限学习机（ELM）模型的线性和非线性预测能力，提出一种基于线性模型与非线性模型相融合的负荷组合预测模型（ARMA-ELM），并采用仿真实验进行了性能测试，验证了ARMA-ELM的有效性以及优越性。

ELM补偿ARMA的电力负荷预测思路

大量研究表明，电力负荷是一个动态的复杂系统，具有随机性、趋势性等变化特点，传统模型以及单一模型无法准确描述变化规律，组合模型的负荷预测建模思路为：首先将电力负荷变化过程看作一个具有已知和未知信息的动态系统，通过ARMA模型对历史数据中的信息进行挖掘，将电力负荷的趋势性特征预测出来，非线性变化特点保存在预

关键词/Keywords

电力负荷 ·
误差补偿 ·
自回归移动平均模型 ·
极限学习机 ·

测结果残差序列中；然后采用神经网络对负荷非线性变化特征进行拟合，得到预测结果残差的预测值，实现ARMA的预测结果补偿；最后得到电力负荷的预测结果。本文模型集成了ARMA预测和神经网络的优点，实现了优势互补。神经网络补偿ARMA的电力负荷建模流程如图1所示。




图1 ARMA-ELM的电力负荷预测流程

ARMA-ELM的电力负荷预测

1. ARMA模型

ARMA是一种由自回归（AR）和移动平均（MA）两部分组成的时间序列预测模型，其形式相当的灵活，当AR=0时，ARMA变为MA(q)；当MA=0时，ARMA变为AR(p)模型。AR(p)为

$$y(t) = v + \varphi_1 y(t-1) + \cdots + \varphi_p y(t-p) + \varepsilon(t) \quad (1)$$

式中， $\varepsilon(t)$ 为误差。

如果 $\varepsilon(t)$ 自相关，那么MA(q)可以表示为

$$\varepsilon(t) = a(t) + \Theta_1 a(t-1) + \cdots + \Theta_p a(t-p) \quad (2)$$

式中， Θ_j 为待估计的参数， $j=1,2,\cdots,p$ ； $a(t)$ 为零均值白噪声。

综上所述，ARMA(p,q)为

$$\begin{aligned} y(t) &= v + \varphi_1 y(t-1) + \cdots + \varphi_p y(t-p) + \varepsilon(t) \\ &= v + \varphi_1 y(t-1) + \cdots + \varphi_p y(t-p) + a(t) + \\ &\quad \Theta_1 a(t-1) + \cdots + \Theta_p a(t-p) \end{aligned} \quad (3)$$

如果阶数n比较大，那么AR(n)可以近似等价于ARMA(p,q)，则有

$$y(t) = v + \sum_{i=1}^n \varphi_i y(t-i) + a_n(t) \quad (4)$$

式中， $a_n(t)$ 为阶数为n时的误差项。

$a_n(t)$ 的估计值为

$$\hat{a}_n(t) = y_t + \sum_{i=1}^n \hat{\varphi}_i y(t-i) - v \quad (5)$$

式中， $\hat{\varphi}_i$ 常通过最小二乘法估计得到。

根据式(5)可以建立ARMA(p,q)，具体如下

$$y(t) = [v, \varphi_1, \cdots, \varphi_p : \Theta_1, \cdots, \Theta_p] \begin{pmatrix} 1 \\ y(t-1) \\ \vdots \\ \hat{a}_n(t-1) \\ \vdots \\ \hat{a}_n(t-q) \end{pmatrix} + a(t) \quad (6)$$

通过采用AIC准则确定ARMA的参数n、p和q，即

$$AIC(p, q) = \ln |\hat{\Sigma}_a(p, q)| + \frac{2}{S} P_{\text{num}} \quad (7)$$

式中，S为样本数目； $\hat{\Sigma}_a(p, q)$ 为 $\hat{a}(t)$ 的协方差矩阵 $\hat{\Sigma}_a$ 的行列式； P_{num} 为待估计参数的个数。

综上所述，采用ARMA模型对电力负荷进行建模与预测，可以描述电力负荷的变化趋势，但是不能刻画出电力负荷的非线性变化趋势，预测准确度不能满足电力负荷的实际需求，由于预测结果的残差包括电力负荷的非线性变化特点，因此本文采用ELM神经网络对ARMA预测结果的残差进行补偿，以提高电力负荷预测的准确度。

2. ELM神经网络

设 x 为输入向量， y 为隐含层的输出向量， o 为输出层的输出向量， d 为网络模型的目标输出向量， $v = (v_1, v_2, v_3, \cdots, v_j, \cdots, v_m)$ 为输入层与隐含层之间的权值矩阵， $w = (w_1, w_2, w_3, \cdots, w_k, \cdots, w_p)$ 为隐含层到输出层之间的权值矩阵，那么第k个输出神经元的输出为

$$o_k = f\left(\sum_{j=0}^m w_{jk} y_j\right) \quad (8)$$

式中， $k=1,2,3,\cdots,p$ 。

隐含层第j个神经元输出为

$$y_j = f\left(\sum_{i=0}^n v_{ij} x_i\right) \quad (9)$$

式中， $j=1,2,3,\cdots,p$ 。

输出层的输出值与目标值之间的误差计算公式为

$$E = \frac{1}{2} \sum_{k=1}^p (d_k - o_k)^2 \quad (10)$$

将式(10)中的误差展开至隐含层,可得

$$E = \frac{1}{2} \sum_{k=1}^p [d_k - f(\sum_{j=0}^m w_{jk} k_{yj})]^2 \quad (11)$$

将式(11)的误差展开至输入层,可得

$$E = \frac{1}{2} \sum_{k=1}^p \left\{ d_k - f \left[\sum_{j=0}^m w_{jk} f \left(\sum_{i=0}^n v_{ij} x_i \right) \right] \right\}^2 \quad (12)$$

采用梯度下降算法对权值 w_{jk} 和 v_{ij} 进行动态调整,以减小输出值与目标值之间的误差,具体如下

$$\begin{cases} \Delta w_{jk} = -\eta \frac{\partial E}{\partial w_{jk}} \\ \Delta v_{ij} = -\eta \frac{\partial E}{\partial v_{ij}} \end{cases} \quad (13)$$

式中, η 为模型的学习速度。

通过学习样本不断地对神经网络进行训练,并不断地调整网络权值,减小输出值与期望值的误差,直至达到预定要求,则学习完成。

3. 神经网络补偿ARMA的电力负荷预测步骤

收集的电力负荷为一维时间序列数据 $\{y_i\}$, $i=1,2,\dots,n$,则可描述为

$$y_i = l_i + n_i \quad (14)$$

式中, l_i 为电力负荷的趋势变化特点; n_i 为电力负荷的非线性变化特点。

神经网络补偿ARMA的电力负荷预测步骤具体如下:

1) 采用ARMA对电力负荷进行建模,得到电力负荷的趋势变化成分预测结果,电力负荷非线性变化成分包含于ARMA模型预测结果的残差中。

2) 设残差序列作为ELM神经网络模型的输入,通过ELM神经网络的学习,建立电力负荷残差的预测方法,并得到ARMA模型预测残差的预测结果。

3) 采用ELM神经网络对ARMA模型预测残差进行补偿,得到电力负荷的最终预测结果。

仿真实验

1. 数据采集

对某市的每小时电力负荷进行仿真实验,

共获得1 500个数据,具体如图2所示。为了使ARMA-ELM的电力负荷预测结果具有可比性,选择ARMA和ELM进行对比实验。使用方均根误差(RMSE)和平均绝对误差百分比(MAPE)作为评价指标,分别定义如下

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (15)$$

$$\text{MAPE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \times 100\% \right| \quad (16)$$

式中, $\hat{y}_i$ 为预测值; y_i 为真实值; n 为预测样本。




图2 电力负荷时间序列

2. 数据预处理

电力负荷受到多种因素影响,数据之间的差异比较大,为了消除数据间差异过大对预测结果的不利影响,对数据进行归一化处理,并加快训练速度,具体如下

$$y' = \frac{y - y_{\min}}{y_{\max} - y_{\min}} \quad (17)$$

最后对最终预测结果进行反归一化处理,计算得到电力负荷的最终预测值,即

$$\hat{y} = y'(y_{\max} - y_{\min}) + y_{\min} \quad (18)$$

式中, y' 为电力负荷的目标输出; $y_{\max}$ 、 $y_{\min}$ 为最大值和最小值; $\hat{y}$ 为模型的输出值。

3. 结果与分析

将训练集输入到ARMA模型中进行建模,并对剩余测试样本进行预测,得到的预测结果如图3所示。从图3可知,ARMA可以对电力负荷的变化趋势进行捕捉,拟合准确度比较高,但是难以全面、准确地描述电力负荷的变化趋势,这主要是因为ARMA模型不能预测电力负荷随机性和非线性的变化趋势。

计算电力负荷真实值与ARMA(3,5)预测结果之间的误差,得到残差序列,并采用关联维方法




图3 ARMA的预测结果

确定残差序列的嵌入维数,结果如图4所示。从图4可知,随着嵌入维数的增加,关联维数也不断增加,当嵌入维数 $m=6$ 时,关联维数达到饱和状态,这表明嵌入维数为6。




图4 计算残差序列的嵌入维

由于随机、非线性变化成分包含于ARMA模型的残差中,因此采用ELM对ARMA模型预测的残差进行拟合,从而完成对ARMA模型预测结果的修正,ELM的电力负荷残差预测结果如图5所示,ARMA-ELM的电力负荷预测结果如图6所示。从图6可知,ARMA-ELM的预测结果准确度同样高于ELM神经网络模型,这主要是由于




图5 ELM对残差序列的预测结果




图6 ARMA-ELM的电力负荷预测结果

ARMA-ELM集成了两者的优点,从不同方面对电力负荷进行描述,能够获得更优的预测结果。

各模型的电力负荷预测误差比较情况如下表所示。从表中的对比结果可知,ARMA-ELM的预测误差要小于单一的ARMA和ELM神经网络,这说明ARMA-ELM能够对电力负荷进行更加准确的预测,预测结果更科学、可靠,实际应用价值更高。

表 不同模型电力负荷预测误差比较

预测模型	RMSE	MAPE
ARMA	9.00	7.74
ELM	8.37	6.70
ARMA-ELM	6.84	5.34

结束语

电力负荷由于受到多种因素的影响,单一模型不能完全挖掘出原始数据序列隐藏的规律,主要是单一的ARMA或者ELM神经网络只能预测趋势变化成分或者非线性变化趋势,难以获得理想的预测效果,预测准确度无法满足实际需求,ARMA-ELM模型集成了ARMA的趋势预测优势和ELM的非线性预测优势,实现了优势互补。仿真实例结果表明,相对于单一电力负荷预测方法,ARMA-ELMN大幅度提高了电力负荷的预测准确度,具有广泛的应用前景。

参考文献

- [1] 张文亮,汤广福,查鲲鹏,等.先进电力电子技术在智能电网中的应用[J].中国电机工程学报,2010,30(4):1-7.
- [2] 雷绍兰,孙才新,周淦,等.电力短期负荷的多变量时间序列线性回归预测方法研究[J].中国电机工程学报,2006,26(2):25-29.
- [3] 黎灿兵,李晓辉,赵瑞,等.电力短期负荷预测相似日选取算法[J].电力系统自动化,2008,32(9):69-73.
- [4] 曾鸣,刘宝华,徐志勇,等.基于混沌模糊神经网络方法的短期负荷预测[J].湖南大学学报:自然科学版,2008,35(1):58-61.

(收稿日期:2015-04-02) EA