

基于线性相关分析的周期自回归短期负荷预测

唐俊杰, 牛焕娜, 杨明皓

(中国农业大学信息与电气工程学院, 北京 100083)

摘要: 对配电系统短期负荷预测的周期自回归模型和配电负荷的周期性进行了研究。采用相关分析法对配电负荷的周期特性作了深入地分析, 研究结果表明配电负荷的日周期性比周周期性更明显; 基于配电负荷的时刻相关性分析, 挑选出对预测结果起决定性作用的特征输入量, 据此提出了改进的配电负荷日周期 PAR 预测模型。实例研究表明, 该模型较常规 PAR 预测模型的预测速度更快、精度更高。

关键词: 短期负荷预测; 周期自回归模型; 线性相关性分析; 配电负荷; 特征输入量

Periodic autoregressive short-term forecasting method based on the linear correlation analysis

TANG Jun-jie, NIU Huan-na, YANG Ming-hao

(College of Information and Electrical Engineering, China Agricultural University, Beijing 100083, China)

Abstract: The periodical auto-regression (PAR) models for short term load forecasting in distribution electric systems and the periodicity of load cycle are investigated. The result of the linear correlation analysis of distribution load curves shows that daily periodicity is more obvious than that of weekly. An improved daily period PAR load forecasting model is proposed accordingly. Based on the correlation analysis of the hourly period of distribution load, main determinants affecting load forecasting results are chosen as the characteristic input variables for the model. The forecast results of the example show that this model is of more distinct performance improvement than that of the normal PAR forecasting models.

Key words: short-term forecasting; periodical auto-regression model; linear correlation analysis; distribution load; characteristic inputs

中图分类号: TM715 文献标识码: A 文章编号: 1674-3415(2010)14-0128-06

0 引言

负荷预测是电力部门的重要工作之一, 以时间期限进行分类, 通常分为长期、中期、短期和超短期负荷预测。短期负荷预测是对未来一小时到一天的预测, 实际工程应用中, 可以为电力系统制定短期运行计划提供数据。目前, 配电网的测量不足、精度低、出现不良数据的几率大, 通常也需要通过短期负荷预测的方法来补充数据。

短期电力负荷的最大特点是具有明显的周期性, 包括^[1]: ①不同日之间 24 h 整体变化规律的相似性; ②不同星期、同一星期类型日的相似性; ③工作日/休息日各自的相似性; ④不同年度的重大节假日负荷曲线的相似性。这些特点说明短期负荷预测应更关注负荷本身的短期周期特性。

目前短期负荷预测的方法很多, 主要分为传统方法和智能方法两大类。常用的传统方法包括: 时间序列法^[2-4]、卡尔曼滤波预测法^[5]、灰色预测法^[6]等; 常用的智能方法包括: 神经网络法^[7-8]、支持向量机预测法^[9-10]、混沌预测法^[11-12]和小波分析法^[13-14]等。周期自回归 (Periodical Auto-Regression, PAR) 模型^[3-4]属于时间序列法中的一种, 与智能算法和其他传统算法相比, 在精度相同的前提下, PAR 具有模型简单、预测速度快的优点。主要缺点在于: 当周期的长度过大时, 会使得模型过于复杂导致预测计算量增大和建模所需样本容量的倍增。而在建立回归模型时, 样本数据可能出现的多重共线性问题可以用样本聚类方法来解决^[2]。

本文采用线性相关分析法对电力负荷周期特性进行分析。通过负荷曲线相关性分析, 研究了电力负荷的日周期特性和周周期特性, 确定了合理的预测模型; 通过时刻相关性分析, 得到预测模型的特

基金项目: “十一五” 国家科技支撑计划 (2006BAJ04B06)

征输入量, 减小了模型的阶数, 从而达到简化模型和提高预测精度的目的。

1 周期自回归模型

电力负荷的历史数据就是按一定时间间隔进行采样记录下来一个时间序列。PAR 模型能够较好地描述时间序列的周期特性, 并利用其周期性方便地对这个序列进行分析和处理。

1.1 周期自回归 (PAR) 的概念

根据文献[15], 假设一个时间序列

$$X_t = \alpha_{0t} + \alpha_{1t}X_{t-1} + \dots + \alpha_{pt}X_{t-p} + \varepsilon_t \quad (1)$$

式中: X_t 表示 t 时刻的负荷值, X_{t-p} 表示 t 时刻的前 p 时刻的负荷值, α_{pt} 表示模型中的第 p 个参数。 ε_t 为随机干扰量。

若满足以下两个条件:

1) ε_t 为平稳白噪声序列, 即 $E(\varepsilon_t) = 0$ 、 $E(\varepsilon_t^2) = \sigma_t^2$;

2) 对于任意 $i=0, 1, \dots, p$, 有 $\alpha_{it} = \alpha_{it+T}$, $\sigma_t^2 = \sigma_{t+T}^2$ 。

其中: $t=0, \pm 1, \pm 2, \dots$, 为整数; T 为一正整数, 则该模型为 PAR 模型。 T 称为 PAR 模型的周期长度, t 称为 PAR 模型的相位, 且 $p \geq T$ 。

文献[3]中提出: 基于 PAR 的短期负荷预测中, 取 $p > T$, 预测精度并没有显著提高, 而运行速度则随参数的增多明显下降。因此, 我们在建立 PAR 模型的时候, 一般取 $p = T$ 。

PAR 模型的特点就是不同周期中的同时刻点有相同的 α_{it} 和 σ_t 值, 即 $\alpha_{it} = \alpha_{it+T}$, $\sigma_t^2 = \sigma_{t+T}^2$ 。当 $T > 1$ 时, 式 (1) 可以改写为:

$$\begin{cases} \hat{X}_{kT+1} = \alpha_{01} + \alpha_{11}X_{kT} + \dots + \alpha_{p1}X_{kT+1-p} + \varepsilon_{kT+1} \\ \hat{X}_{kT+2} = \alpha_{02} + \alpha_{12}X_{kT+1} + \dots + \alpha_{p2}X_{kT+2-p} + \varepsilon_{kT+2} \\ \vdots \\ \hat{X}_{kT+i} = \alpha_{0i} + \alpha_{1i}X_{kT+i-1} + \dots + \alpha_{pi}X_{kT+i-p} + \varepsilon_{kT+i} \\ \vdots \\ \hat{X}_{kT+T} = \alpha_{0T} + \alpha_{1T}X_{kT+T-1} + \dots + \alpha_{pT}X_{kT+T-p} + \varepsilon_{kT+T} \end{cases} \quad (2)$$

式中: \hat{X}_{kT+i} 是负荷预测值; 而 $X_{kT+i-1}, \dots, X_{kT+i-p}$ 则是负荷实测值, $i=1, 2, \dots, T$ 。

由式 (2) 可以看到: 该模型中, 是对周期中的各个时刻点进行单独建模。即同一周期中各个时刻点对应的预测方程的系数都不同。周期长度为 T 的 PAR 模型, 就相应地有 T 个回归方程。

1.2 周周期 PAR 预测模型

采用基本的周周期性 PAR 模型^[4]进行短期负荷预测时, 认为既可以利用负荷的日周期性又可以利用负荷的周周期性, 负荷预测序列的周期 T 为 168, 模型由 168 个预测方程组成, 其中第 t 个方程可表示为

$$\hat{X}_t = \alpha_{0t} + \alpha_{1t}X_{t-1} + \dots + \alpha_{j,t}X_{t-j} + \dots + \alpha_{168,t}X_{t-168} \quad (t=1, 2, \dots, 168) \quad (3)$$

式中: \hat{X}_t 为一个周周期 168 时刻中第 t 时刻的负荷预测值, 是模型的输出量; X_{t-j} 为第 t 时刻的前 j 时刻的负荷实测值 ($j=1, 2, \dots, 168$), 是模型的输入量。

文献[4]在基本周周期 PAR 模型的基础上作了改进, 改进的周周期 PAR 模型保留了基本周周期 PAR 模型。式 (3) 中 168 个输入量中的前 24 个, 在后 144 个输入量中又选取了 6 个特征量作为补充输入, 简化了模型。

2 配电负荷相关性分析

在回归分析中, 输入与输出之间的线性相关性越强, 对输出的结果影响越大。因此, 根据相关性分析的结果, 来对预测模型的输入量进行选择, 可以达到精简模型和提高预测精度的目的。

2.1 日负荷曲线相关性分析

通常认为配电负荷除了具有很明显的周周期性外, 日周期性也很明显。本节将通过大量实际数据的相关分析来确定二者中哪种更为明显。

2.1.1 日负荷曲线相关性分析方法

假设有 L 天的历史数据, 设 Z_i 为第 i 天的日负荷列向量, 顺序存放 24 个整点时刻的负荷值。按照距离当前日期越近列向量的序号越小, 顺序存放日负荷列向量 Z_i ($i=1, 2, \dots, L$), 形成的矩阵称为日负荷矩阵, 记作

$$D_Data = [Z_1 \ Z_2 \ \dots \ Z_{L-1} \ Z_L]_{24 \times L} \quad (4)$$

D_Data 中的任意两列向量的相关系数^[16]为

$$Z_R_{ij} = \frac{\text{Cov}(Z_i, Z_j)}{\sqrt{D(Z_i)}\sqrt{D(Z_j)}} \quad (5)$$

式中: $\text{Cov}(Z_i, Z_j)$ 为矩阵 D_Data 中第 i 列与第 j 列数据的协方差; $\sqrt{D(Z_i)}$, $\sqrt{D(Z_j)}$ 分别为第 i 列、第 j 列数据的均方差。

定义日负荷曲线相关系数矩阵为

$$\begin{cases} B = [b_{ij}]_{(L-7) \times 7} & (i = 1, \dots, L-7) \\ b_{ij} = Z_R_{i, i+j} & (j = 1, \dots, 7) \end{cases} \quad (6)$$

日负荷曲线相关系数矩阵的第*i*行表示的是第*i*天与前1至前7天日负荷曲线的相关系数。将矩阵**B**中的各列分别求平均值，得到各列的平均相关系数*S_j*。

$$S_j = \frac{\sum_{i=1}^{L-7} b_{ij}}{L-7} \quad (j=1, 2, \dots, 7) \quad (7)$$

式中：*S_j*表示所有日负荷曲线与各自前第*j*天日负荷曲线的平均相关系数。值得指出的是，*S₁*反映的是负荷的日周期性，而第七列元*S₇*反映的是负荷的周周期性。*S_j*组成的行向量称为日负荷曲线平均相关系数向量，记作

$$\mathbf{S}=[S_j]_{1 \times 7} \quad (8)$$

2.1.2 实际日负荷曲线相关性分析结果

对某地区 14 台配变 49 天的运行数据，按照 2.1.1 节中的方法，计算得到各台配变的平均相关系数向量 **S**，结果列于表 1。

表 1 实际负荷曲线相关性分析结果

Tab.1 Results of correlation analysis for the actual load curve

配变号	<i>S₁</i>	<i>S₂</i>	<i>S₃</i>	<i>S₄</i>	<i>S₅</i>	<i>S₆</i>	<i>S₇</i>
PB1	0.509	0.532	0.498	0.538	0.494	0.505	0.520
PB2	0.694	0.704	0.675	0.661	0.667	0.659	0.677
PB3	0.827	0.787	0.768	0.738	0.734	0.705	0.701
PB4	0.489	0.474	0.472	0.460	0.476	0.521	0.496
PB5	0.808	0.796	0.769	0.778	0.770	0.752	0.739
PB6	0.311	0.343	0.338	0.324	0.347	0.263	0.254
PB7	0.890	0.879	0.866	0.846	0.852	0.849	0.853
PB8	0.845	0.833	0.827	0.829	0.817	0.812	0.800
PB9	0.658	0.654	0.599	0.609	0.614	0.617	0.629
PB10	0.916	0.892	0.858	0.837	0.845	0.843	0.849
PB11	0.699	0.686	0.654	0.612	0.588	0.581	0.562
PB12	0.769	0.766	0.758	0.743	0.737	0.730	0.716
PB13	0.852	0.858	0.834	0.834	0.839	0.845	0.838
PB14	0.854	0.847	0.832	0.823	0.815	0.814	0.803
总平均值	0.723	0.718	0.696	0.688	0.685	0.678	0.674

从表 1 中的总平均值可以看出，随着天数间隔的增大，相关系数逐渐减小。也就是任一天的负荷曲线与其前 1 天的负荷曲线相关性最大，与上周具有相同星期序号那天负荷曲线的相关性最小。

为了验证表 1 的结论对工作日和休息日是否单独成立，对日负荷曲线相关系数矩阵 **B** 中工作日和休息日分别计算平均相关系数的总平均值，计算结果如表 2 所示。

表 2 区分工作日和休息日后的总平均值

Tab.2 Overall average after distinguishing between days and holidays

	holidays						
总平均值	<i>S₁</i>	<i>S₂</i>	<i>S₃</i>	<i>S₄</i>	<i>S₅</i>	<i>S₆</i>	<i>S₇</i>
工作日	0.726	0.724	0.697	0.682	0.681	0.672	0.673
休息日	0.719	0.701	0.691	0.700	0.699	0.701	0.680

由表 2 可见，无论是工作日还是休息日，日负荷曲线相关性的变化规律都与表 1 相同。由此可见，配电负荷的日负荷曲线的日周期特性比周周期特性更为明显。

2.2 配电负荷时刻相关性分析

配电负荷时刻相关性分析是基于相同时刻负荷形成的数据序列进行，目的在于确定预测时刻之前 24 时刻的负荷对于预测值的影响程度。

2.2.1 负荷时刻相关性分析方法

假设有 *N* 天的历史数据，设 **P_i** 为时刻负荷列向量，按照日期由近至远顺序存放 *N*-1 天相同时刻负荷。由时刻负荷列向量形成时刻负荷矩阵，记作

$$\mathbf{H_Data} = [\mathbf{P}_1 \ \mathbf{P}_2 \ \dots \ \mathbf{P}_{47} \ \mathbf{P}_{48}]_{(N-1) \times 48} \quad (9)$$

式中：前 24 列顺序存放 24 至 1 时刻负荷列向量；后 24 个列向量为前 24 列向量中相应元素的位移。

在 **H_Data** 中，当列号大于 24 时，有

$$\mathbf{P}_i(j) = \mathbf{P}_{i-24}(j+1) \quad (j=1, \dots, N-2) \quad (10)$$

需要注意的是：这样得到的 **P₂₅** 至 **P₄₈** 每列只有 *N*-2 个元素，应该将第 *N* 天的 24 至 1 时刻负荷分别存放到后 24 列中，使得后 24 个列向量与前 24 列具有相同的长度，均为 *N*-1。

H_Data 中的任意两列向量的相关系数^[16]可表示为

$$P_R_{ij} = \frac{\text{Cov}(\mathbf{P}_i, \mathbf{P}_j)}{\sqrt{D(\mathbf{P}_i)}\sqrt{D(\mathbf{P}_j)}} \quad (11)$$

式中：**Cov(P_i, P_j)** 表示矩阵 **H_Data** 中第 *i* 列与第 *j* 列数据的协方差； $\sqrt{D(\mathbf{P}_i)}$ ， $\sqrt{D(\mathbf{P}_j)}$ 分别表示矩阵 **H_Data** 中第 *i* 列、第 *j* 列数据的均方差。

定义时刻负荷相关系数矩阵为

$$\begin{cases} \mathbf{C} = [\mathbf{C}_{ij}]_{24 \times 24} & (i=1, \dots, 24) \\ \mathbf{C}_{ij} = P_R_{i, i+j} & (j=1, \dots, 24) \end{cases} \quad (12)$$

时刻负荷相关系数矩阵 **C** 的第 *i* 行为第 *i* 时刻与前 1 至 24 时刻的相关系数。将矩阵 **C** 中的各列分别求平均值，得到各列的平均相关系数 *H_j*。

$$H_j = \frac{\sum_{i=1}^{24} c_{ij}}{24} \quad (j=1, 2, \dots, 24) \quad (13)$$

H_j 表示一天24个时刻的负荷分别与前第 j 时刻负荷相关系数的平均值(相关系数)。 H_j 组成的行向量称为时刻平均相关系数向量, 记作

$$\mathbf{H}=[H_j]_{1 \times 24} \quad (14)$$

2.2.2 实际负荷时刻相关性分析结果

对某地区14台配变49天的运行数据, 按照2.2.1节中的方法, 计算得到各台配变的时刻平均相关系数向量 \mathbf{H} , 结果列于表3。

表3 负荷时刻相关分析结果

配变号	H_1	H_2	...	H_{23}	H_{24}
PB1	0.596	0.538	...	0.559	0.558
PB2	0.917	0.888	...	0.753	0.741
PB3	0.811	0.708	...	0.632	0.659
⋮	⋮	⋮	⋮	⋮	⋮
PB12	0.572	0.465	...	0.395	0.352
PB13	0.731	0.712	...	0.593	0.584
PB14	0.715	0.758	...	0.654	0.661
总平均值	0.693	0.659	...	0.563	0.569

图1为表3中最后一行总平均值的柱状图。由图中柱状的高低, 我们可以得到一天中任意时刻 t 的负荷与前24个时刻负荷的平均相关程度。按照相关程度由强到弱的时间序列为

$$\mathbf{Q}=[1,2,3,4,24,23,22,21,11,10,20,12,13,5,6,7,8,9,19,17,16,15,14,18] \quad (15)$$

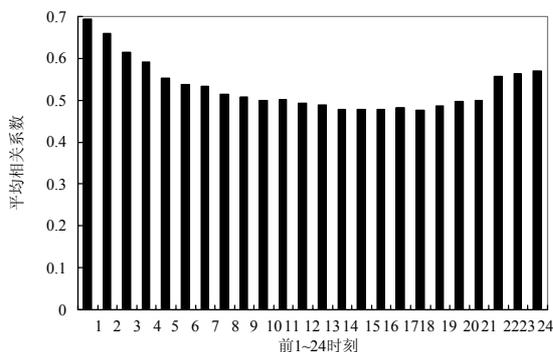


图1 配电负荷与前24时刻的总平均相关系数

Fig.1 Overall average correlation coefficient of distribution load with the former 24 hours

3 改进的日周期 PAR 负荷预测模型

本文依据日负荷曲线相关分析得到配电负荷日

周期性强的结论, 将以往电力负荷预测 PAR 模型^[4]以周为周期改为以日为周期。又根据负荷时刻相关性分析结果, 从中挑选出与预测输出量相关性强的时刻负荷作为预测模型的特征输入量, 从而简化模型的计算规模。

3.1 模型的特征输入量

本文以14台配变2008年1月至2008年8月运行数据作为样本建模, 2008年9月的运行数据作为预测对比的实际值, 按照式(15)给出的时刻顺序依次增加模型的输入量的个数, 对每台配变进行负荷预测仿真试验。总的月平均日负荷预测准确率随着输入量个数增加的变化曲线如图2所示。日负荷预测准确率计算公式^[17]为

$$A = 1 - \sqrt{\frac{1}{n} \sum_{k=1}^n \left(\frac{\hat{X}_k - X_k}{X_k} \right)^2} \times 100\% \quad (16)$$

式中: \hat{X}_k 、 X_k 分别为 k 时刻负荷的日负荷预测值和实际值; n 为预测总点数。

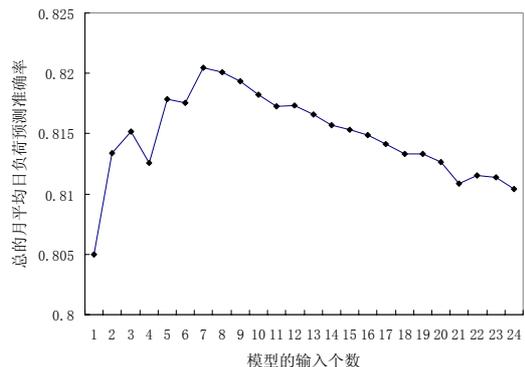


图2 所有配变总预测效果的变化趋势

Fig.2 All distribution transformers with varying trends in the overall predictive power

从图2显示的所有配变总体预测效果来看, PAR模型的输入个数按照相关性递减的顺序增加, 大致呈凸形变化, 并不是个数越多预测的精度越高。在按照时刻序列 \mathbf{Q} 输入前7个元素时, 总的月平均日负荷预测准确率达到最大值。

由此, 选取预测 t 时刻负荷时的平均精度达最高的7个变量作为日周期 PAR 模型的特征输入量。7个特征输入量对应的时刻为

$$\mathbf{Q}_T = [t-1, t-2, t-3, t-4, t-24, t-23, t-22] \quad (17)$$

\mathbf{Q}_T 序列前4个是距时刻 t 过去最近的时刻, 而后3个为上一个日周期对应的 t 时刻和与 t 时刻未来最近的2个时刻。

3.2 改进日周期 PAR 模型

选择序列 \mathbf{Q}_T 中各时刻对应的负荷作为 PAR 模

型的特征输入量, 得到简化的日周期配电负荷预测模型。该模型共有 24 个回归方程组成, 其中第 t 个方程可表示为

$$\hat{X}_t = \alpha_{0t} + \alpha_{1t}X_{t-1} + \alpha_{2t}X_{t-2} + \alpha_{3t}X_{t-3} + \alpha_{4t}X_{t-4} + \alpha_{5t}X_{t-22} + \alpha_{6t}X_{t-23} + \alpha_{7t}X_{t-24} \quad (t=1, 2, \dots, 24) \quad (18)$$

式中: \hat{X}_t 为一个日周期 24 时刻中第 t 时刻的负荷预测值, 是模型的输出量; X_{t-j} 为第 t 时刻的前 j 时刻的负荷实测值 (j 的取值分别为时刻序列 Q_T 对应的 7 个时刻), 是模型的输入量。

3.3 实例

将本文改进的日周期 PAR 模型记为模型一, 将基本日周期 PAR 模型记为模型二, 将文献[4]中基于补充纵分量法的改进周周期 PAR 模型记为模型三。以某地区同一台配变负荷为分析对象, 用于建模的历史数据为 2008 年 6 月 1 日至 2008 年 10 月 12 日共 134 天的运行数据, 分别用三种模型预测该配变 2008 年 10 月 13 日至 2008 年 10 月 19 日一周的日负荷曲线。三种模型的平均准确率、平均中值相对误差 (MPE)^[18] 和预测计算时间 (计算机主频为 1.8 GHz, 内存为 1 G) 列于表 4。

表 4 三种模型预测精度对比表

Tab.4 Three kinds of model prediction accuracy of comparative table

星期	日期	模型一	模型二	模型三
星期一	2008.10.13	0.913	0.895	0.883
星期二	2008.10.14	0.902	0.886	0.871
星期三	2008.10.15	0.893	0.885	0.862
星期四	2008.10.16	0.891	0.876	0.859
星期五	2008.10.17	0.889	0.881	0.864
星期六	2008.10.18	0.905	0.896	0.887
星期日	2008.10.19	0.906	0.893	0.876
平均准确率		90.0%	88.7%	87.2%
平均中值相对误差		6.43%	7.55%	8.61%
平均计算时间/ms		0.022	0.063	0.071

从表 4 中可以看到: 在一周内, 1) 基本日周期 PAR 模型 (模型二) 各天的预测精度均高于文献[4]的改进周周期 PAR 模型 (模型三), 说明利用配电负荷日周期更强的特征可以提高负荷预测的精度; 2) 本文的改进日周期 PAR 模型 (模型一) 的预测精度比模型二的精度进一步提高, 平均预测精度从 0.887 提高到 0.9, 而且计算时间大大减少, 平均计算时间从 0.063 ms 减少到 0.022 ms。

4 结论

本文采用数理统计中线性相关分析法对大量配电负荷的运行数据进行了分析和统计研究, 得到以下结论:

1) 负荷曲线相关性分析结果表明配电负荷的日周期性比周周期性更明显, 利用此特征不仅可以提高负荷预测的精度而且还可以简化模型, 提高计算速度。

2) 本文提出的负荷时刻相关性分析法, 可以给出负荷预测值与过去 24 个时刻负荷的平均相关程度时刻序列, 由该序列可以得到日周期 PAR 模型的特征输入量。

3) 基于所提取的负荷预测特征量输入量, 改进了日周期 PAR 模型, 实例研究表明本文改进日周期 PAR 模型较基本日周期 PAR 模型的预测速度和预测精度都有较大的提高。

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.
KANG Chong-qing, XIA Qing, ZHANG Bo-ming. Review of power system load forecasting and its development[J]. Automation of Electric Power Systems, 2004, 28 (17): 1-11.
- [2] 张伏生, 汪鸿, 韩梯, 等. 基于偏最小二乘回归分析的短期负荷预测[J]. 电网技术, 2003, 27 (3): 36-40.
ZHANG Fu-sheng, WANG Hong, HAN Ti, et al. Short-term load forecasting based on partial least-squares regression[J]. Power System Technology, 2003, 27 (3): 36-40.
- [3] 赵宏伟, 任震, 黄雯莹. 基于周期自回归模型的短期负荷预测[J]. 中国电机工程学报, 1997, 17 (5): 348-351.
ZHAO Hong-wei, REN Zhen, HUANG Wen-ying. A short term load forecasting method based on PAR model[J]. Proceedings of the CSEE, 1997, 17 (5): 348-351.
- [4] 赵宏伟, 任震, 黄雯莹. 考虑周周期性的短期负荷预测[J]. 中国电机工程学报, 1997, 17 (3): 211-216.
ZHAO Hong-wei, REN Zhen, HUANG Wen-ying. Short term load forecasting considering weekly period based on PAR[J]. Proceedings of the CSEE, 1997, 17(3): 211-216.
- [5] 李明干, 孙健利, 刘沛. 基于卡尔曼滤波的电力系统短期负荷预测[J]. 继电器, 2004, 32 (4): 9-12.
LI Ming-gan, SUN Jian-li, LIU Pei. Short-term load forecast power system based on Kalman filter[J]. Relay, 2004, 32 (4): 9-12.

- [6] 张颖, 朱陶业. 基于灰色 GM(1,1) 及其改进型模型的短期电力负荷预报[J]. 电工电能新技术, 2003, 22(2): 23-25.
ZHANG Ying, ZHU Tao-ye. Forecast of electric load based on GM(1,1) and its improved model[J]. Advanced Technology of Electrical Engineering and Energy, 2003, 22(2): 23-25.
- [7] Amjady, Nima. Short-term bus load forecasting of power systems by a new hybrid method[J]. IEEE Transactions on Power Systems, 2007, 22(1): 333-341.
- [8] 张晓, 敬东. 基于快速人工神经网络的短期负荷预测[J]. 继电器, 2000, 28(12): 13-15, 23.
ZHANG Xiao, JING Dong. Short-term load forecasting using artificial neural network and adaptive fuzzy system[J]. Relay, 2000, 28(12): 13-15, 23.
- [9] 潘峰, 程浩忠, 杨镜非, 等. 基于支持向量机的电力系统短期负荷预测[J]. 电网技术, 2004, 28(21): 39-42.
PAN Feng, CHENG Hao-zhong, YANG Jing-fei, et al. Power system short-term load forecasting based on support vector machines[J]. Power System Technology, 2004, 28(21): 39-42.
- [10] YANG Kui-he, SHAN Gan-lin, ZHAO Ling-ling. Correlation coefficient method for support vector machine input samples[C].//Proceedings of the 2006 International Conference on Machine Learning and Cybernetics. 2006: 2857-2861.
- [11] 方仍存, 周建中, 彭兵, 等. 电力负荷混沌动力特性及其短期预测[J]. 电网技术, 2004, 32(4): 61-66.
FANG Reng-cun, ZHOU Jian-zhong, PENG Bing, et al. Chaotic dynamics of power load and its short-term forecasting[J]. Power System Technology, 2004, 32(4): 61-66.
- [12] 梁志珊, 王丽敏, 付大鹏, 等. 基于 Lyapunov 电力系统短期负荷预测[J]. 中国电机工程学报, 1998, 18(5): 368-371.
LIANG Zhi-shan, WANG Li-min, FU Da-peng, et al. Electric power system short-term load forecasting using Lyapunov exponents technique[J]. Proceedings of the CSEE, 1998, 18(5): 368-371.
- [13] 郇能灵, 侯志俭, 李涛, 等. 基于小波分析的电力系统短期负荷预测方法[J]. 中国电机工程学报, 2003, 23(1): 45-50.
TAI Neng-ling, HOU Zhi-jian, LI Tao, et al. New principle based on wavelet transform for power system short-term load forecasting[J]. Proceedings of the CSEE, 2003, 23(1): 45-50.
- [14] Chang C S, FU Wei-hui, YI Min-jun. Short-term load forecasting using wavelet networks[J]. International Journal of Engineering Intelligent Systems for Electrical Engineering and Communications, 1998, 6(4): 217-223.
- [15] 安鸿志, 吴国富. 周期自回归模型及其在经济预测中的应用[J]. 数理统计与应用概率, 1993, 8(4): 1-13.
AN Hong-zhi, WU Guo-fu. Periodical auto regression model and its application in economic forecasting[J]. Mathematical Statistics and Applied Probability, 1993, 8(4): 1-13.
- [16] 盛骤, 谢式千, 潘承毅. 概率论与数理统计[M]. 三版. 北京: 高等教育出版社, 2000.
SHENG Zhou, XIE Shi-qian, PAN Cheng-yi. Probability theory and mathematical statistics[M]. Third edition. Beijing: Higher Education Press, 2000.
- [17] 陈亚红, 马丽, 穆钢, 等. 两种短期负荷预测精度考核标准的比较[J]. 电力系统自动化, 2003, 27(17): 73-77.
CHEN Ya-hong, MA Li, MU Gang, et al. Comparison studies on two types of accuracy criteria for short-term load forecast[J]. Automation of Electric Power Systems, 2003, 27(17): 73-77.
- [18] 祝金荣, 胡望斌. 聚类电价预测方法研究[J]. 电子科技大学学报, 2007, 36(6): 1278-1281.
ZHU Jin-rong, HU Wang-bin. Forecasting of electricity prices with cluster analysis[J]. Journal of University of Electronic Science and Technology of China, 2007, 36(6): 1278-1281.

收稿日期: 2009-08-28; 修回日期: 2009-09-15

作者简介:

唐俊杰(1984-), 男, 硕士研究生, 研究方向为输配电网状态估计、电力负荷预测算法研究;

牛焕娜(1976-), 女, 助理研究员, 博士研究生, 研究方向为配网自动化、电力系统运行与控制;

杨明皓(1953-), 女, 博士生导师, 教授, 研究方向为电力系统运行与控制、配电自动化、可再生能源发电。

E-mail: mhyang@cau.edu.cn