

DOI: 10.7667/PSPC161188

基于并行膜计算的短期电力负荷组合预测

白杨¹, 赵冠¹, 窦金廷¹, 黄国强¹, 闫敏¹, 李逐云², 雷霞², 刘增庆²

(1. 国网山东省电力公司聊城供电公司, 山东 聊城 252000;
2. 流体及动力机械教育部重点实验室(西华大学), 四川 成都 610039)

摘要: 提出一种并行膜计算(Parallel Membrane Computing, PMC)的电力负荷短期组合预测方法。将线性回归模型、趋势外推模型、改进灰色模型和粒子群优化参数的支持向量机分别放入膜系统的基本膜中, 同时并行预测, 然后把预测结果输出到表层膜。在表层膜中组合得出最终预测值, 组合优化以各种方法预测结果的几何平均数与加权组合结果之差的平方值最小为目标函数, 并采用改进粒子群算法分时段优化出权重系数。此外, 在进行预测前对历史数据进行了改进滑动平均处理, 并采用系统聚类法选出计算输入的历史数据。并行膜计算可以极大地提高组合预测速度, 以多种方法预测结果的几何平均数代替真实值确立组合预测模型的目标函数更具实用性。最后, 仿真结果验证了所提方法的合理性和有效性。

关键词: 组合预测; 并行膜计算(PMC); 系统聚类; 改进粒子群算法; 几何平均数

Short-term power load combination forecasting based on parallel membrane computing

BAI Yang¹, ZHAO Guan¹, DOU Jinyan¹, HUANG Guoqiang¹, YAN Min¹, LI Zhuyun², LEI Xia², LIU Zengqing²

(1. Liaocheng Power Supply Company, State Grid Shandong Electric Power Company, Liaocheng 252000, China;
2. Key Laboratory of Fluid and Power Machinery, Ministry of Education (Xihua University), Chengdu 610039, China)

Abstract: A method of parallel membrane computing (PMC) is proposed to solve the combination of short-term load forecasting. The linear regression model, trend extrapolation model, improved gray model and support vector machines with particle swarm optimization parameters are used to forecast load concurrently in different basic membranes of membrane system, and the prediction results are all output to the surface membrane. In the surface membrane, the ultimate results are got by combined optimization, which is to minimize the square value of geometric mean of above prediction values minus weighted combination result. The weighted coefficient is time-interval optimized by the improved particle swarm method. In addition, historical data has been improved through moving average processing before making the prediction, and can be selected through system clustering method. Parallel membrane computing can greatly improve composition prediction speed. The method that geometric mean of various prediction results replaces real data in objective function has more practicability. Finally, the simulation results show the rationality and effectiveness of the proposed method.

Key words: combined forecast; parallel membrane computing (PMC); clustering system; improved particle swarm optimization; geometric mean

0 引言

电力系统短期负荷预测是实现电力系统安全、可靠运行的基础, 也是电力系统经济调度的依据^[1]。对于一个电力调度系统而言, 只有得到准确的短时段负荷预测信息, 才能在调度计划中实现机组的最优组合分配, 提高电网运行的可靠性和经济性^[2-3]。目前的电力系统短期负荷预测方法主要分为以经典

数学为理论的传统预测方法, 包括灰色预测法、线性回归法、趋势外推法等^[4-5]; 以人工智能算法为依托的预测方法, 包括神经网络法(ANN)、支持向量机法(SVM)等^[6-8]。

由于影响负荷的因素具有极大的复杂性和不确定性, 而单一预测方法又存在一定的局限性, 其预测精度往往不能满足预测要求。因此, 通过组合预测将不同负荷预测方法或结果有机结合在一起, 取

长补短,可有效减少预测误差。根据组合方法的不同,目前的组合预测模型主要有两种类型^[9]:一种是在建模过程中,将不同原理的预测方法进行组合,渐进求得组合最优。文献[10]先采用小波变换技术序列分解历史负荷数据,再利用纵横交叉算法优化的神经网络对单支重构所得的负荷子序列进行预测,最后组合各子序列的预测值从而得出最终结果。文献[11]根据小波变换自适应可调时频窗的特点,将负荷做了不同尺度的分解,然后利用模糊理论对除开大尺度分量的其他负荷信号进行处理,最后通过序列重构,得到完整的负荷预测结果。文献[12]首先利用集合经验模态分解把历史数据分解为相对平稳的子序列,再对子序列用最小二乘支持向量机预测,然后叠加预测结果得出最终值。另一种则是在单一预测原理的基础上,对预测结果加权组合。典型的组合方法有:等权平均组合预测法、方差-协方差法、最优权系数法等。其中等权平均组合预测法具有稳定性高的优点,已被广泛地运用在组合预测领域,但是此方法较为简单,没有对各方法权重系数进行优化;对于方差-协方差组合预测法,其目标函数为预测值与真实值的协方差最小,此方法是在已知真实值情况下建立的模型,不具有实际意义^[13]。除此之外,组合预测方法虽然可以提高预测精度,但是随着预测方法及模型复杂程度的增加,预测时间也会增加,这将对电力系统实时调度产生一定的影响^[14]。

本文提出一种并行膜计算的电力负荷短期组合预测方法,将线性回归模型、趋势外推模型、改进灰色模型和粒子群优化参数的支持向量机(SVM)分别放入膜系统的基本膜中,同时并行预测,以提高预测速度。将各预测结果输出到表层膜,在其中建立以各种预测结果几何平均数与加权组合结果差值的平方值最小为目标函数的组合模型,并采用改进粒子群算法(PSO)分时段优化出各种方法的权重系数。最后,通过仿真算例分析了最终的预测结果,并分别与单一模型、等权组合模型以及协方差组合模型的结果进行了对比,证明了所提方法的合理性和有效性。

1 历史数据处理与分析

1.1 改进滑动平均法

为了降低原始数据中异常值的作用以及提炼出整个数据序列的规律性,本文采用改进滑动平均法对负荷数据进行了预处理。在计算某一数据的滑动平均值时不仅利用原始数列信息而且引入了其前一数据滑动平均后的值,从而增加了前后数据的关联

度,进一步降低了数值波动量。记原始数列为 $\{x^{(0)}(t)\}, t=1,2,\dots,n$,则改进滑动平均法计算如下:

$$\begin{cases} x^{(1)}(t) = \frac{x^{(0)}(t-1) + 2x^{(0)}(t) + x^{(0)}(t+1)}{4} & 1 < t < n \\ x^{(1)}(1) = \frac{3x^{(0)}(1) + x^{(0)}(2)}{4} \\ x^{(1)}(n) = \frac{x^{(0)}(n-1) + 3x^{(0)}(n)}{4} \end{cases} \quad (1)$$

式中, $x^{(0)}(t)$, $x^{(1)}(t)$ 分别表示滑动平均前后的数据值。

1.2 系统聚类

本文所获得的历史数据为预测日前5年每天96点的负荷值,面对如此大的数据量,有必要从中选择出适宜用作预测的数据信息,在此采用系统聚类法并结合“近大远小”原则,先选择出与预测日同季度的前3年的历史数据,再利用系统聚类法对此数列进行聚类分析,最后选取与预测日属于同类的负荷数据作为预测的输入样本。

系统聚类法的基本原理为:首先,令 n 个样本自成一类,并规定样本之间的距离和类与类之间的距离(初始时类间距离与样本间距离是等价的);然后,把距离最小的两个类合并成一个新类,并算出新类与其他类间的距离;再按照最小距离准则并类,重复进行两个最近类的合并,这样每次减少一类,持续下去直到所有样品都归为一类为止。其流程如图1所示。

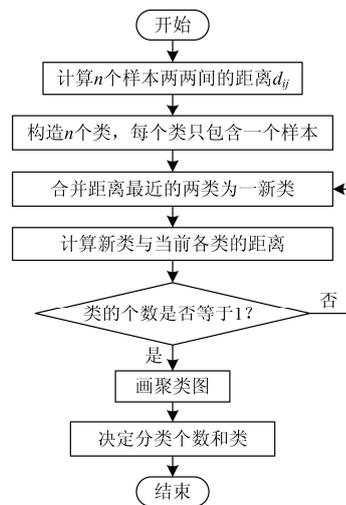


图1 系统聚类法的流程

Fig. 1 Flow of system clustering method

本文采用类平均法(以两类样本两两之间平方

距离的平均值作为类间距离)来计算各类之间的距离,如式(2)。

$$D_{G_i, G_j} = \sqrt{\frac{1}{n_1 + n_2} \sum_{i \in G_i} \sum_{j \in G_j} d_{ij}^2} \quad (2)$$

式中: i, j 分别表示类 G_i 和 G_j 中的任意两个样本; n_1, n_2 分别表示类 G_i 和 G_j 中的样本数; d_{ij} 表示 i, j 两个样本的距离。

2 预测方法的并行膜计算

膜计算^[15]作为自然计算的一个新分支,其是受生物细胞启发,从活细胞以及由生命细胞组成的器官或组织的结构和功能中抽象出的一种计算模型。

膜结构中含有不同层次的膜,若某一膜内不含其他任何膜,则该膜为基本膜;若某一膜位于系统的最外层,则该膜为表层膜。在膜系统里,每层膜均有其对应区域,其中的对象多重集和进化规则存放于此区域里,能够引导膜的正常运行。

为利用并行计算速度快的优点,把其与膜计算相结合,形成并行膜计算(PMC)^[16]。本文在膜结构中将不同的预测模型作为各膜内的运行规则,将负荷历史数据作为各膜内的对象多重集,以此在不同的基本膜内进行多种方法的并行预测,最后将各基本膜内的预测结果输出到表层膜,进行下一步的组合预测。

本文提出的并行膜计算构建了一个 5 层膜系统,其结构如图 2 所示,表示为如下的多元组。

$$\Pi = (V, T, \mu, \omega_1, \omega_2, \omega_3, \omega_4, G_1, G_2, G_3, G_4, (R_1, \rho_1), (R_2, \rho_2), (R_3, \rho_3), (R_4, \rho_4)) \quad (3)$$

式中: V 为对象字母表; T 为输出字母表; μ 为膜结构; $\omega_i (1 \leq i \leq 4)$ 为区域 i 的对象多重集字符串; $G_i (1 \leq i \leq 4)$ 为区域 i 内所有对象的数量; $R_i (1 \leq i \leq 4)$ 为区域 i 内进化规则的有限集; $\rho_i (1 \leq i \leq 4)$ 为 R_i 中的偏序关系,也称优先关系。

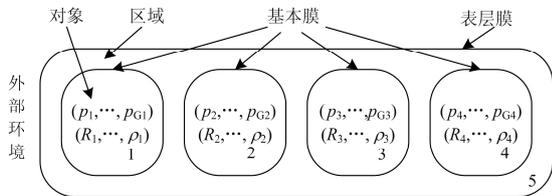


图 2 并行膜计算膜结构

Fig. 2 Membrane structure of PMC

如图 2 所示,在 1~4 号膜内并行实现线性回归模型、趋势外推模型、改进灰色模型以及 SVM 的负荷预测,最后将 4 种预测方法的结果输出到 5 号膜内,进行组合分析。其中,在 4 号膜内采用支持

向量机预测时,为了实现 SVM 参数的自动选择以及控制参数的搜寻方向,将 PSO 与 SVM 进行结合,利用 PSO 的全局搜索能力对 SVM 中的参数进行优化,实现找寻最佳参数 C 与 g 的目标。

3 组合预测模型及算法

3.1 模型建立

本文将线性回归模型、季节型趋势外推模型、改进灰色模型和 SVM 4 种方法进行组合,建立了以各种方法预测结果的几何平均数与加权组合结果之差的平方值最小为目标函数的组合预测模型。

季节型趋势外推模型考虑到了负荷数据在季度和月份上呈周期性变化的趋势,从而利用这种趋势对未来负荷进行预测;灰色预测模型主要是针对信息不完全或数据有缺失的情况,通过数据处理将灰色领域转化为白色领域,进而利用历史数据建立微分方程实现负荷预测;线性回归模型通过对数据进行统计分析,确定变量之间的相关关系,从而达到预测的目的;SVM 是建立在统计学理论上的一种新型预测方法,其回归估计算法通过引入不敏感损失函数和核函数,而被广泛地应用于负荷预测^[4-6]。

考虑到目前所用到的组合预测模型,大多均将实际负荷作为一种修正预测模型的基准值,间接影响各种方法权重系数的分配^[17-18],然而在实际短期负荷预测中,并没有真实数据进行参考比较。因此,本文采用各种方法预测结果的几何平均数取代传统组合模型里作为修正基准值的实际负荷,建立以多个预测结果的几何平均数与加权组合结果之差的平方值最小为目标的组合预测模型,并通过改进 PSO 进行求解,分时段优化出组合权重。所建模型的目标函数如下所示。

$$\min f_2 = \sum_{i=1}^n \left(\bar{y}_k - \sum_{k=1}^k w_k y_k \right)^2 \quad (4)$$

$$\bar{y}_k = \left(\prod_{k=1}^k y_k \right)^{\wedge(1/k)} \quad (5)$$

式中: n 为周期内预测时段数; k 为预测方法数; w_k 为第 k 种方法对应的权重系数,为本文的优化变量; y_k 为各种方法得到的预测值; \bar{y}_k 为各种方法预测结果的几何平均数。

约束条件主要考虑各个方法的权重系数之和为 1 以及各权重系数取值约束,表示为

$$\begin{cases} \sum_{k=1}^k w_k = 1 \\ 0 \leq w_k \leq 1 \quad k = 1, 2, 3, 4 \end{cases} \quad (6)$$

3.2 改进粒子群算法

粒子群算法(Particle Swarm Optimization, PSO)具有收敛速度快、参数可调等特性,而电力组合负荷预测是一种非线性连续优化问题。故用粒子群算法来解决电力组合负荷预测问题是非常适合的,但是基本粒子群优化算法存在容易早熟、后期易在全局最优解附近产生震荡现象等缺点。

惯性权重 w 可平衡 PSO 算法全局和局部搜索能力,当 w 较大时,全局搜索能力强;当 w 较小时,局部搜索能力强,可提高搜索精度。本文对基本粒子群算法进行改进,使用线性递减粒惯性权重的粒子群算法来优化求解电力组合负荷(LWPSO)预测模型^[19],利用线性变化的权重,使 w 从最大值 w_{max} 线性减小到最小值 w_{min} ,其变化公式为

$$w = \begin{cases} w_{min} + \frac{(w_{max} - w_{min})(f_k - f_{min})}{f_{avg} - f_{min}} & f_k \leq f_{avg} \\ w_{max} & f_k > f_{avg} \end{cases} \quad (7)$$

式中: f_{avg}, f_{min} 分别为当前整个粒子群体适应值的平均值和最小值; w_{min}, w_{max} 分别为算法的最小最大惯性权重; f_k 为粒子 k 当前的适应值。

3.3 组合预测流程

基于 PMC 的短期电力负荷组合预测的流程如图 3 所示。

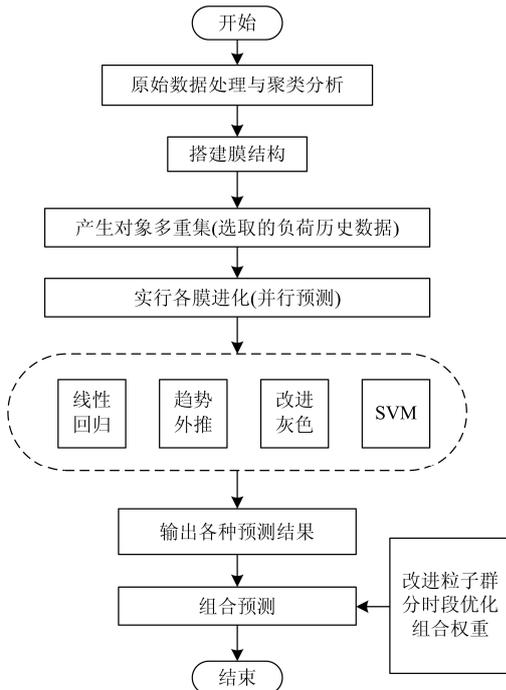


图 3 组合预测流程图

Fig. 3 Flow of combination forecasting

4 算例分析

4.1 样本输入量的确定

针对某地区 2009.01.01~2015.01.05 的历史负荷数据,利用本文所提方法对 2015 年 1 月 6 日 96 个时间点的负荷值进行仿真预测。首先提取出 2012 到 2015 年 11 月~1 月的负荷数据进行改进的滑动平均处理;然后对处理后的数据进行系统聚类,将这一批数据分为 3 类,分类结果如表 1 所示;最后,因预测日为星期二且与其距离最近的上一个星期二(2014.12.30)为 C 类,故选择 C 类数据作为样本输入量。

表 1 聚类分析结果

Table 1 Result of cluster analysis

A 类	B 类		C 类
20120102	20120101	20131124	2012~2015 年其余日
20120115	20120119	20131201	
20120116	20120120	20131215	
20120117	20120121	20131222	
20120118	20120122	20131231	
20120130	20120123	20140102	
20120131	20120124	20140105	
20130101	20120125	20140112	
20140101	20120126	20140117	
20140123	20120127	20140119	
20140124	20120128	20140120	
20140125	20120129	20140121	
20140126	20130102	20140122	
20140127	20130106	20141102	
20140128	20130113	20141109	
20140129	20130120	20141116	
20140130	20130126	20141123	
20140131	20130127	20141130	
20150101	20130128	20141207	
20150102	20130129	20141214	
	20130130	20141221	
	20130131	20141228	
	20131103	20141231	
	20131110	20150103	
	20131117	20150104	

4.2 单一方法预测结果

采用上文提到的 4 种单一预测方法,针对选择出的样本进行负荷预测,得到各种方法的预测相对误差如图 4 所示。

图 4 中纵坐标相对误差绝对值的计算式如下: $e_i = |(\hat{y}_i - y_i)/y_i|, i=1, \dots, 96$, 其中 i 为日负荷预测时段, \hat{y}_i 为预测值, y_i 为实际值。

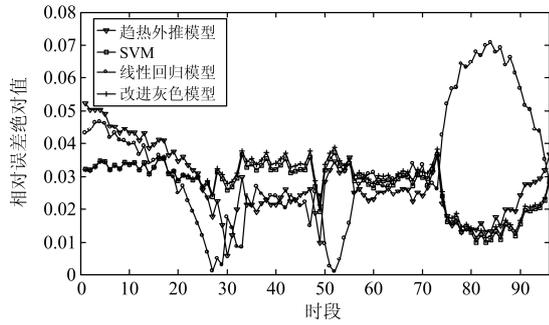


图4 单一预测方法的相对误差

Fig. 4 Relative error of the single forecast method

由图4可以发现,在4种方法中SVM和改进灰色模型预测精度相对高一些,两者中SVM的效果更好,其相对误差范围在[1.0%, 3.7%],线性回归模型的预测效果最差,其误差最大达到了7.1%,趋势外推模型预测结果的平均误差较小(2.8%),但是其最大误差为5.2%,总体上效果不好。

4.3 组合方法预测结果

利用本文所提的PMC组合预测方法,针对同样的输入数据进行负荷预测。在膜结构里的4个基本膜内实现4种单一方法的并行预测,将各预测结果输出到表层膜后采用改进粒子群算法分时段优化出一天96个时间点4种模型的权重系数,进而进行组合预测。其中,PMC组合预测结果如图5所示,优化出的权重系数见附录表A1。

由表A1可以看出,一天中各时间点的模型权重是变化的,即针对不同的时段各种预测方法的精度是不同的,因此采用分时段优化权重系数较固定权重类的方法而言具有更大的实际意义。

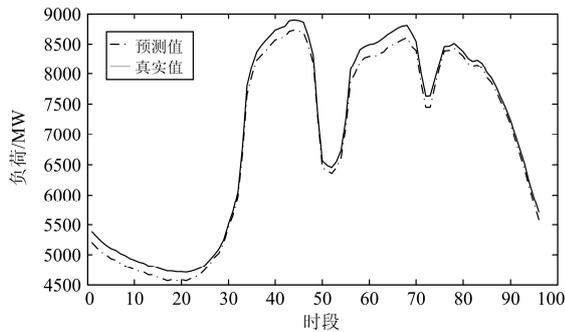


图5 组合预测结果曲线

Fig. 5 Combination forecasting profile

从图5中可以发现,由PMC组合预测方法求得的负荷曲线与真实负荷曲线的走势基本一致,且两条曲线比较靠近,没有出现严重偏离的情况。同时,对预测结果的相对误差进行计算,可得到96个时段中最大相对误差为3.1%,最小相对误差仅为

0.8%,说明PMC组合预测方法具有较大的准确性,可以满足一定的精度要求。

本文采用一天96个时段预测结果的相对误差平均值 e_{avg} 和相对误差最大值 e_{max} 来评价各种预测方法,结果如表2所示。其中, e_{avg} , e_{max} 表示如下:

$$e_{avg} = \frac{1}{96} \sum_{i=1}^{96} |(\hat{y}_i - y_i) / y_i| \times 100\% \quad (8)$$

$$e_{max} = \max_{i=1, \dots, 96} \{ |(\hat{y}_i - y_i) / y_i| \times 100\% \} \quad (9)$$

式中各符号意义同4.2节。

表2 预测方法比较

Table 2 Comparison of forecasting methods

误差指标	PMC组合	等权组合	协方差组合	趋势外推	改进灰色	线性回归	SVM
$e_{avg}(\%)$	2.0	2.1	1.9	2.8	2.9	3.3	2.8
$e_{max}(\%)$	3.1	3.8	3.7	5.2	3.9	7.1	3.7

由表2可得:

1) PMC组合预测方法的平均误差和最大误差均小于各种单一预测方法的对应值,即所提模型的结果优于各单一模型,达到了优势互补的效果。

2) PMC组合预测方法的平均误差和最大误差均小于等权组合模型的对应值,这体现出采用改进粒子群算法分时段优化权重系数的组合方法较等权组合方法具有更大的优越性。

3) PMC组合预测在平均误差这一指标上稍差于协方差组合模型,这是因为协方差组合模型是以负荷真实值来建立目标函数的,其理论上应该效果更好,但是本文所提方法的预测精度比较高,而且在建模中没有引入真实负荷,这更具有实际意义。

为了说明组合预测方法采用并行运算的时间优势,表3中对传统组合和PMC组合的计算时间进行了比较。

表3 计算时间比较

Table 3 Computing time comparison

预测方法	时间/s
传统组合预测	42.8358
PMC组合预测	11.1097

由表3可以发现,在多核计算机中采用并行膜计算同时进行4种单一模型的预测使得整个组合预测的计算时间大为缩短,这对系统的调度和实时运行控制意义重大。

5 结论

本文提出了一种基于并行膜计算的电力负荷短期组合预测方法。先将线性回归模型、趋势外推模

型、改进灰色模型和 SVM 放入膜系统里 4 个基本膜中，同时并行预测，后将预测结果输出到表层膜里进行加权组合。考虑到现实中负荷真实值的未知性，建立了以各预测结果的几何平均数与加权组合结果之差的平方值最小为目标函数的组合预测模型，并通过改进粒子群算法分时段优化求解出权重系数。算例分析中，利用某地区真实负荷数据，首先对数据进行改进滑动平均处理，然后利用系统聚类法，将有相似性的情景聚成 3 类，最后选出和预测日同类型的历史数据作为输入样本。将本文模型、

等权组合模型、协方差模型和单一模型进行对比，并通过相对误差、平均误差等评价指标来判断各种方法的预测精度。由仿真结果可知，所提方法比 4 种单一预测模型和等权组合模型的误差更小，虽然与协方差模型相比平均误差稍大，但是协方差模型是以真实负荷值来选择权系数，所以在允许的精度范围内所提方法具有更大的实用意义。此外，采用并行膜计算后预测时间比传统预测用时更少，表明所提预测方法在提高精度的同时也提高了速度。

附录

表 A1 单一预测方法的权系数
Table A1 Weight of the single forecast method

时段	M1	M2	M3	M4	时段	M1	M2	M3	M4
1	0.000	0.061	0.345	0.594	49	0.082	0.151	0.499	0.267
2	0.000	1.000	0.000	0.000	50	0.436	0.270	0.034	0.260
3	0.000	0.989	0.059	0.000	51	0.339	0.343	0.068	0.249
4	0.000	0.579	0.426	0.000	52	0.473	0.248	0.016	0.263
5	0.418	0.639	0.058	0.000	53	0.054	0.365	0.341	0.240
6	0.341	0.200	0.141	0.317	54	0.005	0.393	0.356	0.246
7	0.105	0.219	0.391	0.285	55	0.000	0.016	0.743	0.241
8	0.470	0.541	0.000	0.000	56	0.385	0.220	0.135	0.261
9	0.010	0.000	0.352	0.638	57	0.074	0.404	0.280	0.242
10	0.479	0.211	0.000	0.310	58	0.000	0.464	0.304	0.231
11	0.644	0.315	0.050	0.000	59	0.658	0.046	0.013	0.284
12	0.317	0.460	0.233	0.000	60	0.711	0.000	0.007	0.282
13	0.387	0.530	0.182	0.000	61	0.172	0.183	0.387	0.258
14	0.161	0.325	0.524	0.000	62	0.344	0.306	0.096	0.254
15	0.487	0.288	0.244	0.000	63	0.231	0.070	0.436	0.263
16	0.340	0.197	0.556	0.000	64	0.454	0.083	0.195	0.268
17	0.583	0.192	0.231	0.000	65	0.434	0.191	0.111	0.264
18	0.464	0.000	0.497	0.000	66	0.425	0.302	0.017	0.256
19	0.025	0.000	0.985	0.000	67	0.226	0.408	0.121	0.245
20	0.611	0.185	0.039	0.165	68	0.077	0.638	0.065	0.219
21	0.576	0.158	0.160	0.106	69	0.397	0.042	0.284	0.277
22	0.415	0.076	0.338	0.171	70	0.185	0.290	0.274	0.250
23	0.539	0.000	0.275	0.186	71	0.010	0.504	0.250	0.237
24	0.002	0.717	0.000	0.282	72	0.219	0.000	0.522	0.258
25	0.359	0.000	0.380	0.261	73	0.000	0.487	0.266	0.248
26	0.498	0.226	0.009	0.266	74	0.723	0.000	0.000	0.277
27	0.000	0.796	0.107	0.097	75	0.064	0.038	0.651	0.248
28	0.401	0.328	0.039	0.232	76	0.270	0.474	0.000	0.255
29	0.119	0.529	0.228	0.124	77	0.204	0.072	0.466	0.258
30	0.290	0.020	0.328	0.362	78	0.425	0.094	0.221	0.261

续表 A1

时段/min	M1	M2	M3	M4	时段/min	M1	M2	M3	M4
31	0.363	0.302	0.095	0.239	79	0.159	0.128	0.457	0.256
32	0.329	0.229	0.180	0.262	80	0.614	0.012	0.113	0.261
33	0.267	0.043	0.405	0.285	81	0.106	0.599	0.022	0.272
34	0.397	0.270	0.078	0.255	82	0.302	0.179	0.262	0.256
35	0.000	0.002	0.694	0.304	83	0.000	0.379	0.362	0.259
36	0.169	0.668	0.000	0.163	84	0.182	0.493	0.060	0.265
37	0.000	0.000	0.702	0.298	85	0.249	0.356	0.131	0.264
38	0.236	0.068	0.402	0.295	86	0.165	0.079	0.508	0.248
39	0.128	0.580	0.104	0.189	87	0.322	0.291	0.126	0.262
40	0.526	0.049	0.122	0.303	88	0.283	0.245	0.214	0.258
41	0.196	0.526	0.076	0.203	89	0.389	0.204	0.152	0.255
42	0.026	0.614	0.172	0.188	90	0.133	0.573	0.000	0.295
43	0.309	0.145	0.272	0.274	91	0.010	0.395	0.325	0.270
44	0.389	0.000	0.311	0.300	92	0.490	0.019	0.258	0.234
45	0.347	0.176	0.209	0.269	93	0.371	0.273	0.095	0.262
46	0.151	0.341	0.268	0.240	94	0.000	0.585	0.114	0.301
47	0.088	0.224	0.435	0.253	95	0.440	0.000	0.341	0.218
48	0.143	0.593	0.068	0.197	96	0.207	0.278	0.256	0.259

注: 表中 M1~M4 分别表示趋势外推、改进灰色、线性回归、SVM 4 种预测方法; 表中每个时段为 15 min, 一天分为 96 个时段。

参考文献

- [1] DE FELICE M, YAO X. Short-term load forecasting with neural network ensembles: a comparative study application notes[J]. Computational Intelligence Magazine IEEE, 2011, 6(3): 47-56.
- [2] 谷云东, 张素杰, 冯君淑. 大用户电力负荷的多模型模糊综合预测[J]. 电工技术学报, 2015, 30(23): 110-115.
GU Yundong, ZHANG Sujie, FENG Junshu. Multi-model fuzzy synthesis forecasting of electric power loads for larger consumers[J]. Transactions of China Electrotechnical Society, 2015, 30(23): 110-115.
- [3] 丁宁. 含风电的电力系统多时间尺度经济调度研究[J]. 陕西电力, 2015, 43(9): 10-14.
DING Ling. A multi time-scale rolling coordination scheduling method for power grid integrated with wind power[J]. Shaanxi Electric Power, 2015, 43(9): 10-14.
- [4] SONG K B, BAEK Y S, HONG D H, et al. Short-term load forecasting for the holidays using fuzzy linear regression method[J]. IEEE Transactions on Power Systems, 2005, 20(1): 96-101.
- [5] LIU Y, ZHAI M Y, LU L P, et al. An improved method for short-term power load forecasting based on fractal extrapolation[J]. Applied Mechanics & Materials, 2012, 229: 1077-1080.
- [6] 王东, 史晓霞, 尹交英. 不同核函数的支持向量机用于空调负荷预测的对比研究[J]. 电工技术学报, 2015, 30(增刊 1): 531-535.
WANG Dong, SHI Xiaoxia, YIN Jiaoying. Prediction on hourly load of air conditioning by rbf support vector machine[J]. Transactions of China Electrotechnical Society, 2015, 30(S1): 531-535.
- [7] 李龙, 魏靖, 黎灿兵, 等. 基于人工神经网络的负荷模型预测[J]. 电工技术学报, 2015, 30(8): 225-230.
LI Long, WEI Jing, LI Canbing, et al. Prediction of load model based on artificial neural network[J]. Transactions of China Electrotechnical Society, 2015, 30(8): 225-230.
- [8] 孙景文, 常鲜戎. 基于高斯混沌粒子群优化动态前馈神经网络的短期负荷预测[J]. 陕西电力, 2015, 43(9): 67-69.
SUN Jingwen, CHANG Xianrong. Short term load forecasting based on DFNN optimization by GCP SO[J]. Shaanxi Electric Power, 2015, 43(9): 67-69.
- [9] 柏建良. 组合预测模型在湖州电网短期负荷预测中的应用[D]. 北京: 华北电力大学, 2015.
BO Jianliang. The application of combination forecasting model in short-term load forecasting on Huzhou grid[D]. Beijing: North China Electric Power University, 2015.

[10] 孟安波, 胡函武, 刘向东. 基于纵横交叉算法优化神经网络的负荷预测模型[J]. 电力系统保护与控制, 2016, 44(7): 102-106.
MENG Anbo, HU Hanwu, LIU Xiangdong. Short-term load forecasting using neural network based on wavelets and crisscross optimization algorithm[J]. Power System Protection and Control, 2016, 44(7): 102-106.

[11] 邵能灵, 侯志俭. 小波模糊神经网络在电力系统短期负荷预测中的应用[J]. 中国电机工程学报, 2004, 24(1): 24-29.
TAI Nengling, HOU Zhijian. New short-term load forecasting principle with the wavelet transform fuzzy neural network for the power systems[J]. Proceedings of the CSEE, 2004, 24(1): 24-29.

[12] 王新, 孟玲玲. 基于 EEMD-LSSVM 的超短期负荷预测[J]. 电力系统保护与控制, 2015, 43(1): 61-66.
WANG Xin, MENG Lingling. Ultra-short-term load forecasting based on EEMD-LSSVM[J]. Power System Protection and Control, 2015, 43(1): 61-66.

[13] 牛东晓. 电力负荷预测技术及其应用[M]. 北京: 中国电力出版社, 1998.

[14] 陈超. 电力系统短期负荷预测研究[D]. 昆明: 昆明理工大学, 2014.
CHEN Chao. Short-term load forecasting power system[D]. Kunming: Kunming University of Science and Technology, 2014.

[15] PAUN G. Membrane computing[M]. Germany: Springer Verlag Berlin and Heidelberg Gmb H & Co K, 2010.

[16] 吴泓俭. 基于膜优化算法的含新能源的配电网重构[D]. 成都: 西华大学, 2015.
WU Hongjian. Network reconfiguration with new energy based on membrane optimization algorithms[D]. Chengdu: Xihua University, 2015.

[17] 王宁, 谢敏, 邓佳梁, 等. 基于支持向量机回归组合模型的中长期降温负荷预测[J]. 电力系统保护与控制, 2016, 44(3): 92-97.
WANG Ning, XIE Min, DENG Jialiang, et al. Mid-long term temperature-lowering load forecasting based on combination of support vector machine and multiple regression[J]. Power System Protection and Control, 2016, 44(3): 92-97.

[18] 张栋梁, 严健, 李晓波, 等. 基于马尔可夫链筛选组合预测模型的中长期负荷预测方法[J]. 电力系统保护与控制, 2016, 44(12): 63-67.
ZHANG Dongliang, YAN Jian, LI Xiaobo, et al. Mid-long term load forecasting based on Markov chain screening combination forecasting models[J]. Power System Protection and Control, 2016, 44(12): 63-67.

[19] 蔺海明, 刘天琪, 李兴源. 考虑风电出力 and 负荷不确定性的电力系统有功优化潮流[J]. 电网技术, 2013, 37(6): 1584-1589.
LIN Haiming, LIU Tianqi, LI Xingyuan. Optimal active power flow considering uncertainties of wind power output and load[J]. Power System Technology, 2013, 37(6): 1584-1589.

收稿日期: 2016-08-01; 修回日期: 2016-10-31

作者简介:

白 杨(1981-), 男, 工程师, 主要从事电网运行方式管理工作; E-mail: 363908882@qq.com

赵 冠(1986-), 女, 工程师, 主要从事继电保护整定计算工作;

窦金延(1986-), 女, 工程师, 主要从事电网运行方式管理工作。

(编辑 魏小丽)