

基于大数据和优化神经网络短期电力负荷预测

金鑫¹, 李龙威¹, 季佳男², 李祉歧³, 胡宇³, 赵永彬⁴

(1. 中央财经大学信息学院, 北京 100081; 2. 人力资源和社会保障部人事考试中心, 北京 100011;
3. 北京国电网络技术有限公司, 北京 100070; 4. 国网辽宁省电力有限公司信息通信分公司, 辽宁 沈阳 110006)

摘 要: 随着电力数据采集成本降低及大规模电网互联等因素, 电网中可获取的数据类型日益丰富。以往的集中式预测方法对海量电力数据的分析能力有限。提出基于大数据和粒子群优化 BP 神经网络短期电力负荷预测, 建立短期电力负荷预测模型。利用国家电网的实际负荷数据, 采用所提方法进行预测, 与实际负荷数据及集中式负荷预测结果进行比较, 结果证明, 所提方法预测精度较高, 降低了负荷预测时间, 在实际应用中具有可行性。

关键词: 电力大数据; 粒子群算法; 并行 PSO 优化神经网络; 电力负荷预测; 电力负荷影响因素

中图分类号: TP391

文献标识码: A

Power short-term load forecasting based on big data and optimization neural network

JIN Xin¹, LI Long-wei¹, JI Jia-nan², LI Zhi-qi³, HU Yu³, ZHAO Yong-bin⁴

(1. School of Information, Central University of Finance and Economics, Beijing 100081, China;
2. Personnel Testing Center, Ministry of Human Resources and Social Security, Beijing 100011, China;
3. Beijing State Power Communication Network Technology Company, Beijing 100070, China;
4. Liaoning Power Supply Company ICT Branch of State Grid Corporation, Shenyang 110006, China)

Abstract: With the reduction of the cost of power data acquisition and the interconnection of large scale power systems, the types of data available in the power network are becoming more and more abundant. In the past, the centralized forecasting method was limited to the analysis of the massive power data. Therefore, a short-term power load forecasting based on large data and particle swarm optimization BP neural network was proposed, and short-term power load forecasting model was established. The actual load data of the national grid, using the method of prediction, compared with the actual load data and centralized load forecasting results prove that this method is accurate enough, reduce the load forecasting time with feasibility in practical application.

Key words: electric power data, particle swarm algorithm, parallel PSO to optimize the neural network, power load forecasting, power load factor

1 引言

电力系统负荷预测的水平成为衡量电力系统管理现代化的标志之一^[1]。短期负荷预测是电力系统负荷预测的重要组成部分^[2]。随着电力市场改革, 电力短期负荷预测精度直接影响电网及发电厂的经济效益^[3]。近年来, 世界各国都在积极开展智能

电网的研究工作。电网发电、调度、通信等环节的检测仪、传感器等是电网大数据的主要源头。此外, 与电力系统负荷预测相关的气象系统等与电力企业内部系统的交互程度在日益加深。大数据技术为电力负荷预测带来了新的机遇和挑战^[4]。

电力系统最主要的任务是要为广大用户提供安全、可靠的电源, 因此, 电力负荷预测是实现电力系

收稿日期: 2016-08-30

基金项目: 国家自然科学基金资助项目 (No.U1509214); 国网科技部基金资助项目 (No.SGTYHT/14-JS-188)

Foundation Items: The National Natural Science Foundation of China (No.U1509214), Technology Project of State Grid Corporation of China (No.SGTYHT/14-JS-188)

统稳定可靠运行的基础,按照时间周期可将电力负荷预测分为长期、中期、短期、超短期负荷预测。不同时间周期的预测对象和内容以及用途也各不相同。本文主要是面向电力短期负荷预测,其预测的对象是某天内每个时刻电网的负荷,主要内容是日用电量,主要用于电力公司制定日发电供电计划。

近年来,人们对电力负荷预测做了大量的研究工作,但是由于电力负荷具有地域性,各地影响电力负荷的因素各不相同,很多研究只是针对某个地区的电力负荷特性,如文献[5,6]就对我国广州和常德等地区的电力负荷特性进行了研究。在影响因素方面,文献[7]提出负荷与天气突变修正策略,增强了电力负荷预测模型对气象因素的适应能力;文献[8]在气象因素的基础上添加了气温累加效应对电力负荷变化的影响;文献[9]对不同行业的用电量进行了建模和预测;文献[10]分析了台风期间的气象因素与电力系统负荷之间的关系;由此可见,短期的电力负荷预测影响因素正在向综合多种因素的复杂化处理方法发展。在预测方法方面,大致分为以下几种方法^[11~14]:传统预测方法,文献[14~16]采用线性回归方法对未来的电力负荷进行预测;时间预测方法,主要以 Box-jenkins 提出的时间预测方法为代表;灰色预测方法,近期的以神经网络和支持向量机为代表的智能预测方法,如 Bahman 采用神经网络对日本的长期负荷进行了预测^[17],文献[18,19]采用遗传算法对历史负荷数据进行分析,对台湾的年负荷进行了预测。

以上方法和理论具有很多参考借鉴的方面,但是仍然有很多不足的地方,比如只是基于小范围的预测,大规模数据的获取反而不利于真实有效的信息;并且以上的预测方法多针对小数据量,没有考虑大规模数据的特点,预测效果不佳,因此,需要一种结合现有大数据技术的预测算法。

2 基于大数据的电力短期负荷变化规律分析

随着我国经济的发展,电力需求量在飞速增长,电网供电区域在不断拓展,电力的生产和供应形式多样,归属于同一电网的不同地区,用户行为存在明显差异,为准确预测电网短期负荷变化规律,需要利用电网大数据的优势,对电网负荷变化规律进行细化分析。重点分析待测地区不同区域夏季电力负荷与外部因素的关系,为下一步电力负荷预测奠定基础。

2.1 电力短期负荷影响因素数据收集

在大数据兴起之前,由于数据采集成本较高,电网的信息化主要以业务为主,只能获取跟业务相关的最小数据集。因此,早期电网数据信息相对较少,没有对大规模电力负荷进行预测的条件。大数据技术的发展和国家的大力支持以及智能电网的广泛建设为大规模电力负荷预测提供可能。

基于大数据对电力负荷变化规律及其相关因素进行分析,其基础是要对影响因素进行收集和和处理。本文所采用的数据主要由国家电网公司提供,相关信息主要从以下方式获取。

- 1) 电网公司内部资料。主要是电网公司财务、调度、规划等,可以间接反映用户用电情况。
- 2) 客户资料。客户个人信息与其用电情况有直接关系,如用户性质(商用、民用等)、工业用户的淡旺季、居民小区位置等。
- 3) 政府部门统计和规划资料,如气象局、统计局等,可以获取与电力负荷相关的环境因素等。

以上所需收集的数据是分析电网电力负荷变化的基础。

2.2 夏季电网日负荷变化规律分析

本文主要针对南方某省进行研究,该地区面积较为宽广,各地区电力负荷影响因素不同,各因素对负荷变化规律也不是孤立的,因此,各地区的负荷特性呈现不同规律。电力负荷预测的基础是变化规律的分析,本文主要针对夏季电网日负荷变化规律进行分析,重点是夏季短期负荷预测。

图 1 为 A 市一周的负荷曲线,可以看出,工作日电网负荷变化曲线相似,周六、周日要稍低一些,这是因为电力负荷与工业用电和居民生活用电相关性较高的因素。




图 1 A 市一周(2014 年 7 月 9 日至 15 日)负荷曲线

图 2 是 A 市一天的负荷曲线，可以看出，一天的负荷变化具有一定的规律性，一般 0:00 之后电网负荷开始减少，3:00~4:00 达到最低值，6:00 之后开始快速上升，虽然节假日会有所不同，但大体走势保持一致。




图 2 A 市 7 月 1 日负荷曲线

2.3 电网负荷和影响因素数据预处理

各地区电力负荷及其变化规律受各种因素影响，本文采用皮尔逊相关系数计算负荷与其影响因素的相关系数。

$$R_{l-x} = \frac{\sum_{i=1}^n (l_i - \bar{l})(x_i - \bar{x})}{\sqrt{\sum_{i=1}^n (l_i - \bar{l})^2 \sum_{i=1}^n (x_i - \bar{x})^2}}$$

其中， $\bar{l} = \frac{1}{n} \sum_{i=1}^n l_i$ ， $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$ ； n 代表时间段内的时间点数； x 代表电网负荷影响因素； l_i 代表时间段内各个时间点的负荷； x_i 是各个时间点影响因素的量化值。 R_{l-x} 取值范围是 $[-1,1]$ ，其值表示不同程度的相关性。对应关系如表 1 所示。

表 1 R_{l-x} 值与相关程度关系

$ R_{l-x} $	线性相关程度
$[0,0.3)$	低度线性相关
$[0.3,0.5)$	中低度线性相关
$[0.5,0.8)$	中度相性相关
$[0.8,1]$	高度线性相关

对电网历史负荷数据的归一化处理主要是为了避免输入和输出数据因数量级差别较大对预测结果产生不良影响，提高预测准确性和预测效率。本文的归一化和反归一化计算式如下

$$y = \frac{2(x - x_{\min})}{x_{\max} - x_{\min}} - 1$$

$$x = \frac{1}{2}(x_{\max} - x_{\min})y + \frac{1}{2}(x_{\max} + x_{\min})y$$

其中， x_{\max} 和 x_{\min} 分别表示未处理负荷样本每行的最大和最小值。 x 是待处理的历史负荷数据， y 是经过归一化的预测负荷数据。

本文参考文献[20]对温度的处理方法，对温度根据区间进行量化，如图 3 所示。借鉴文献[21]对气象数据进行量化来定性描述气象状况对电力短期负荷预测的影响[22]。本文将日期类型分为 4 类：周一取 0.7，周二至周五取 0.9，周六取 0.4，周日取 0.3。




图 3 温度区间及其量化值

3 基于大数据的电力短期负荷预测方法

因预测的范围较广，电力负荷和气象分布又具有一定的地域特征。使用集中式的电力负荷预测方法对系统负荷进行预测准确率，且不能够完全发挥大数据对海量数据的挖掘能力。在电力数据海量增长的同时，工业负荷变化频繁，冲击性负荷增多，导致电力负荷特性日益复杂，因此，本文提出符合大数据的电力负荷预测方法，提高电网的负荷预测效率和精度。

3.1 BP 神经网络和 PSO 算法建模过程

神经网络是由大量神经元组成的非线性系统，每个神经元的功能和结构都比较简单，但大量神经网络组合成的神经网络系统非常复杂，该系统通过其状态对外部的输入信息产生动态响应来处理信息[23]。BP 神经网络是单向传播的多层网络，主要有 3 层，输入层、隐含层和输出层[24]，分为正向和反向传播。通过正向传播和反向传播误差来调整各层权值，权值调整的过程就是 BP 神经网络的学习训练过程，减小输出误差，这个过程是循环往复的，直到达到终止条件。

图 4 是本文设计的含一个隐含层的神经网络预测模型。




图 4 神经网络预测模型

输入层共有 15 个节点，其中，包含 12 个时间点的电力负荷数据以及 3 个影响因子（气温、天气、日期）经过归一化和量化后的数据。记为 $x_k=(x_{k1}, x_{k2}, \dots, x_{kh}, \dots, x_{k15})$ 。输出层有 1 个节点，代表对预测日的不同时间点分别建立模型进行预测；隐含层的节点数，由经验公式 $m = \sqrt{n+l} + a$ 。其中， m 代表隐含层节点个数， n 代表输入层节点数， l 表示代表层节点数， a 取 1~10 之间的常数。考虑结果的准确性，分别试算节点数为 5、6、7，最终选择隐含层的节点数为 6。隐含层和输出层的转移函数采用双极性 S 型函数

$$f(x) = \frac{2}{1+e^{-x}} - 1 = \frac{1-e^{-x}}{1+e^{-x}}$$

输入层与隐含层之间的权值矩阵用 V 来表示，隐含层到输出层的权值矩阵用 W 表示，对于隐层有

$$y_j = f(net_j), j = 1, 2, \dots, w$$

$$net_j = \sum_{i=0}^n v_{ij} x_i, j = 1, 2, \dots, m$$

对于输出层有

$$O_k = f(net_k), k = 1, 2, \dots, m$$

$$net_j = \sum_{i=0}^n w_{jk} y_i, j = 1, 2, \dots, w$$

PSO 算法是一种基于群体智能理论的随机全局优化技术，它的思想来源于人工生命和演化计算理论^[25]，基本概念来源于对鸟群捕食行为的研究^[26,27]。PSO 算法思想是：将个体看作是多维空间的粒子，每个粒子有一个初速度，根据自身飞行经验和群体经验对自己的状态进行修正。假设第 i 个粒子的位置 Y_i 和速度 V_i 分别为

$$Y_i = (Y_{i1}, Y_{i2}, \dots, Y_{in})$$

$$V_i = (V_{i1}, V_{i2}, \dots, V_{in})$$

第 i 个粒子的历史最优解是

$$P_i = (P_{i1}, P_{i2}, \dots, P_{in})$$

粒子群粒子最优解为

$$P_m = (P_{m1}, P_{m2}, \dots, P_{mn})$$

粒子的速度和位置按以下方程进行更新

$$V_{in}(t+1) = wv_{in}(t) + c_1 r_1 (P_{in} - x_{id}(t)) + c_2 r_2 (P_{mm} - x_{in}(t))$$

$$Y_{in}(t+1) = Y_{in}(t) + V_{in}(t+1)$$

其中， w 被称作惯性因子，取值范围是[0.4~0.9]； c_1 、 c_2 是学习因子，值为 2。 r_1 、 r_2 取分布在[0,1]内的随

机数。

3.2 PSO 优化神经网络算法

粒子群和神经网络是不同的优化策略，在适用问题和信息处理的方式上有很多区别^[28]。神经网络可以被用来进行模式识别、优化控制和负荷预测等；粒子群算法主要适用于信号处理和函数机制等。二者可以相互结合，形成更为有效的优化方法。本文利用粒子群算法的全局搜索能力优化神经网络的权值，来提高神经网络的学习能力和预测效率。算法流程如图 5 所示。

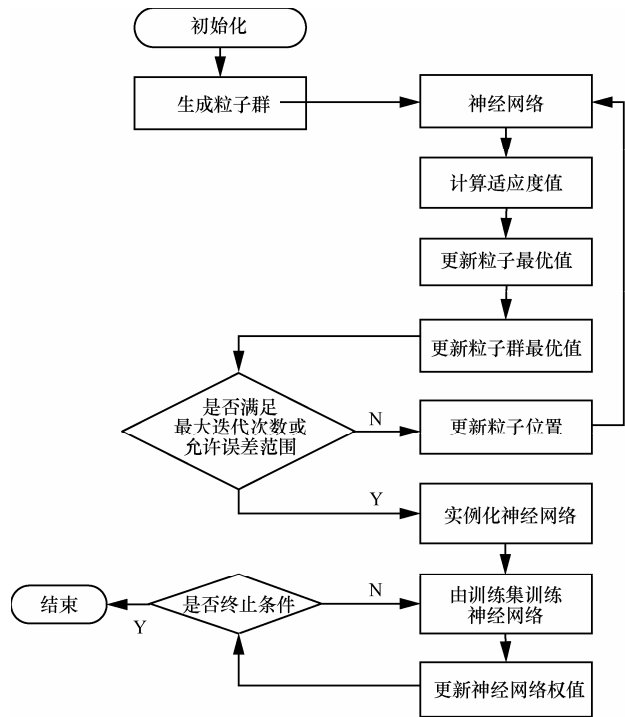


图 5 粒子群优化 BP 神经网络算法流程

算法 1 粒子群优化 BP 神经网络算法

输入 训练集，测试集，最大迭代次数

输出 PSO 优化神经网络模型，性能评估表

Begin

/*初始化粒子群 */

for Index=1:dimsz

postion=x(Index)+x(dimsz+Index);

if postion>particle_dimension_maxValue

postion= particle_dimension_maxValue;

else if postion<particle_dimension_minValue

postion= particle_dimension_minValue;

end

x(Index)=postion;

```

end
for iter=1:iterMax
    for particleIndex=1:particleIndexSize;
        let Result=
            Partfit<objFun(pBest)&&cycInd<MaxInd;
        while(Result is Ture)
            /*由 PSO 更新神经网络权值*/
            let(y0,y1,⋯,yn-1)=updating(x0,x1,⋯,xn-1);
            let Result=Particle_fitness(y0,y1,⋯,yn-1);
            continue;
        end
    end
end
/*检测神经网络模型 */
let Model=get_model(Result);
let train_set=training_set(t1,t2,⋯,ti);
let Result= cycle_Index>cycle_Index_max;
while (Result is False)
    let (t'1,t'2,⋯,t'i)=compute(Model, t1,t2,⋯,ti);
if (Result is Ture)
    return (Model, Performace_Evaluation_results);
else
    return 0;
end
end
    
```

4 实验分析

实验使用平台配置：ThinkServer RD650，处理器类型是 6 核 Intel®Xeon® CPU E5-2620@2.40 GHz，

内存 64 GB，硬盘 16 TB。

本实验数据集由电网公司提供，包含历史负荷值和天气等影响因素，选取 1:00~12:00 的样本。经过归一化处理与 3 个影响因子（气温、天气和日期）组成训练样本，以便分析和处理。

通过将实际值、神经网络预测结果和粒子群优化神经网络预测结果进行对比（如图 6 所示）可以看出，粒子群优化神经网络预测电力短期负荷的精确性要高于未经优化的神经网络。




图 6 PSO 优化神经网络与神经网络和实际值对比

采用粒子群优化的 BP 神经网络预测模型对 A 市 2015 年 7 月 10 日用电负荷进行预测，预测结果及误差如表 2 所示。

表 2 预测结果及误差

时间	预测值/W	实际值/mW	误差	相对误差
1:00	0.224 25	0.212 1	-0.012 15	-5.41%
2:00	0.133 88	0.131 5	-0.002 38	-1.77%
3:00	0.141 14	0.112 1	-0.029 04	-20.57%
4:00	0.218 80	0.228 7	0.009 9	4.52%
5:00	0.578 75	0.616 2	0.037 42	6.47%
6:00	0.624 15	0.632 1	0.007 95	1.27%
7:00	0.655 24	0.655 2	0.000 24	0.06%
8:00	0.714 50	0.725 4	0.010 9	1.52%
9:00	0.715 47	0.726 1	0.010 63	1.48%
10:00	0.784 56	0.788 0	0.003 44	0.43%
11:00	0.835 42	0.843 1	0.007 68	0.91%
12:00	0.845 56	0.856 4	0.010 84	0.12%

预测结果对比如表 3 所示。

表 3 预测结果对比

模型	平均相对误差	训练步数	泛化能力
基本 BP 神经网络	1.88%	216	差
改进的神经网络算法	1.68%	7	一般
粒子群优化神经网络模型	1.20%	4	强

从表 2 和表 3 可以看出, 粒子群优化 BP 神经网络模型优于一般的 BP 神经网络模型, 主要表现为以下 3 方面。

1) 预测精度。根据表 2 和表 3 的相对误差可以看出基于粒子群优化 BP 神经网络模型的预测精度最高。

2) 泛化能力。基于粒子群优化 BP 神经网络的泛化能力强于一般的 BP 神经网络, 在拟合误差较大时, 预测误差也会相对稳定。

3) 收敛速度。从表 3 可以看出, 粒子群优化 BP 神经网络算法所需的迭代次数远远小于一般的神经网络, 从而使训练时间大大减小。

本文为了验证算法效果, 引进改进的神经网络算法进行对比, 经过多次验证, 基于大数据和粒子群优化 BP 神经网络对电网短期负荷进行预测具有预测速度快、精度高等特点。

5 结束语

通过对基于大数据和粒子群优化 BP 神经网络的电力短期负荷预测的研究和实现, 可以发现该模型能够结合大数据和神经网络的优点, 对电力短期负荷具有非常好的预测作用。因此, 采用基于大数据和粒子群优化 BP 神经网络对电力短期负荷预测具有重要意义, 可为电网发电、调度、通信等环节提供可靠支持。

参考文献:

- [1] 刘玲. 基于粒子群 BP 神经网络的短期负荷预测研究[D]. 江苏: 河海大学, 2006.
LIU L. Short-term load forecasting based on particle swarm neural network research[D]. Jiangsu: HHU, 2006.
- [2] 陆宁, 周建中, 何耀耀, 等. 粒子群优化的神经网络模型在短期负荷预测中的应用[J]. 电力系统保护与控制, 2010, 38(12): 2010, 38(12): 65-68.
LU N, ZHOU J Z, HE Y Y, et al. Particle swarm optimization-based neural network model for short-term load forecasting[J]. Power Sys-

- tem Protection and Control, 2010, 38(12): 65-68.
- [3] HIPPER H S, PERFREIRA C E, SOUZA R C. Neural network for short-term load forecasting: a review and evaluation[J]. IEEE Transactions on Power Systems, 2001, 16(2): 44-54.
- [4] 宋亚奇, 周国亮, 朱永利. 智能电网大数据处理技术现状和挑战[J]. 电网技术, 2013, 37(4): 927-935.
SONG Y Q, ZHOU G L, ZHU Y L. Present status and challenges of big data processing in smart grid[J]. Fudan International Studies Review, 2013, 37(4): 927-935.
- [5] 陈健, 刘明波, 樊亚亮, 等. 广州电网负荷特性分析[J]. 电力系统及其自动化学报, 2009, 21(6): 78-83.
CHEN J, LIU M B, FAN Y L, et al. Studies on load characteristics of Guangzhou power network[J]. Proceedings of the Chinese Society of Universities, 2009, 21(6): 78-83.
- [6] 廖峰, 徐聪颖, 姚建刚, 等. 常德地区负荷特性及其影响因素分析[J]. 电网技术, 2012, 36(7): 117-125.
LIAO F, XU C Y, YAO J G, et al. Load characteristics of Changde region and analysis on its influencing factors[J]. Power System Technology, 2012, 36(7): 117-125.
- [7] 李明, 王智灵, 杨晓宇, 等. 突变期电力负荷预测方法及其应用[J]. 电力系统自动化, 2006, 30(10): 93-96.
LI M, WANG Z L, YANG X Y, et al. Short-term load forecasting for abnormal changes and its application[J]. Automation of Electric Power Systems, 2006, 30(10): 93-96.
- [8] 康重庆, 固安石, 王鹏, 等. 短期负荷预测中实时气象因素的影响分析及其处理策略[J]. 电网技术, 2006, 30(7): 5-10.
KANG C Q, ZHOU A S, WANG P, et al. Impact analysis of hourly weather factors in short-term load forecasting and its processing strategy[J]. Power System Technology, 2006, 30(7): 5-10.
- [9] BENAOUA D, MURTAGH F, STARCK J L, et al. Wavelet-based nonlinear multiscale decomposition model for electricity load forecasting. Neurocomputing, 2006, 70(1): 139-154.
- [10] 李小燕, 文福栓, 卢恩, 等. 基于相似日负荷修正的台风期间短期负荷预测[J]. 电力系统及其自动化学报, 2013, 25(3): 82-89.
LI X Y, WEN F S, LU E, et al. Short-term load forecasting in Typhoon periods based on load modification of similar days[J]. Proceedings of the CSU-EPSA, 2013, 25(3): 82-89.
- [11] SONG K B, YONG S B, HONG D H, et al. Short-term load forecasting for the holidays using fuzzy liner regression method[J]. IEEE Transactions Power Systems, 2005, 20(1): 96-101.
- [12] 李玲玲, 朱博. 基于混沌时间序列的短期电力负荷预测[J]. 信息技术, 2009(3): 44-46.
LI L L, ZHU B. Short-time power load forecast based on chaotic time series[J]. Information Technology, 2009(3): 44-46.
- [13] 朱陶艺, 李应求, 张颖, 等. 提高时间序列气象适应性的短期电力负荷预测算法[J]. 中国电机工程学报, 2006, 26(23): 14-19.
ZHU T Y, LI Y Q, ZHANG Y, et al. A new algorithm of advancing weather adaptability based on arima model for day-ahead power load forecasting[J]. Proceedings of the Chinese Society for Electrical Engineering, 2006, 26(23): 14-29.
- [14] 张思远, 何光宇, 梅生伟, 等. 基于相似时间序列检索的超短期负

- 荷预测[J]. 电网技术, 2008, 32(12): 6-59.
- ZHANG S Y, HE G Y, MEI S W, et al. Ultra-short term load forecasting based on similarity search in time-series[J]. Power System Technology, 2008, 32(12): 56-59.
- [15] 程其云. 基于数据挖掘的电力短期负荷预测模型及方法的研究[D]. 重庆: 重庆大学, 2004: 5-30.
- CHENG Q Y. Power short-term load forecasting model based on data mining, and methods of research[D]. Chongqing: Chongqing University, 2004: 5-30.
- [16] 赵宏伟, 任震, 黄雯莹, 等. 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 H W, REN Z, HUANG W Y, et al. A short term load forecasting method based on PAR model[J]. Proceedings of the CSEE, 1997, 17(5): 348-351.
- [17] BAHNAM K. Up to year 2020 load forecasting using neural nets[J]. Electric Power and Energy Systems, 2002, 24(9): 789-797.
- [18] PING F, PAI W C H. Support vector machines with simulated annealing algorithms in electricity load forecasting[J]. Energy Conversion and Management, 2005, 46(17): 2669-2688.
- [19] PING F, PAI W C H. Forecasting regional electricity load based on recurrent support vector machines with genetic algorithms[J]. Electric Power Systems Research, 2005, 74(3): 417-425.
- [20] 牛东晓, 曹树华, 卢建昌, 等. 电力负荷预测技术及其应用[M]. 北京: 中国电力出版社, 2009.
- NIU D X, CAO S H, LU J C, et al. Power load forecasting technique and its application[M]. Beijing: China Electric Power Press, 2009.
- [21] LIU K. Comparison of very short-term load forecasting technique[J]. IEEE Trans on Power System, 1996, 11(2): 877-822.
- [22] 刘明. 基于小波和神经网络理论的电力系统负荷预测研究[D]. 南京理工大学, 2012.
- LIU M. Based on wavelet and neural network theory of power system load forecasting research[D]. NUST, 2012.
- [23] 谢勃. 中长期电力负荷预测的不确定性模型研究与应用[D]. 河海大学, 2007.
- XIE B. The uncertainty of the medium and long term power load forecasting model research and application[D]. Jiangsu: HHU, 2007.
- [24] 吕昌国. 基于 BP 算法的网格资源调度研究[D]. 哈尔滨: 哈尔滨理工大学, 2007.
- LV C G. Grid resources scheduling research based on BP algorithm[D]. Harbin: HUST, 2007.
- [25] 袁瑛. 粒子群算法在电力系统经济调度中的应用研究[D]. 西安: 西安理工大学, 2010.
- YUAN Y. Particle swarm algorithm application in power system economic operation[D]. Xi'an: Xi'an University of Technology, 2010.
- [26] LEE K Y, ELSHARKAWI M A. Modern heuristic optimization techniques with applications to power systems. IEEE Power Engineering Society, 2002, 10(6): 45-51.
- [27] KENNEDY J, EBERHART C. A discrete binary version of the particle swarm algorithm[J]. IEEE Trans on Power Systems, 2007, 12(5): 4104-4109.
- [28] 李澄非. 计算智能方法研究及其在流程工业中应用[D]. 北京: 北京化工大学, 2007.
- LI C F. Computational intelligence methods and its application in process industry[D]. Beijing: Beijing University of Chemical Technology, 2007.

作者简介:



金鑫 (1974-), 男, 内蒙古乌海人, 中央财经大学教授, 主要研究方向为商务智能。

李龙威 (1992-), 男, 河南周口人, 中央财经大学硕士生, 主要研究方向为大数据。

季佳男 (1986-), 女, 北京人, 人力资源和社会保障部人事考试中心工程师, 主要研究方向为管理信息系统。

李祉歧 (1986-), 男, 黑龙江鹤岗人, 北京国电网络技术有限公司工程师, 主要研究方向为电力云计算系统架构。

胡宇 (1980-), 男, 黑龙江黑河人, 北京国电网络技术有限公司工程师, 主要研究方向为电力信息化。

赵永彬 (1975-), 男, 辽宁建昌人, 国网辽宁省电力有限公司信息通信分公司高级工程师, 主要研究方向为电力信息化。