

# 基于RF变量选择与LSTM回归的长期用电量预测模型

吴翔宇<sup>1</sup>, 荀超<sup>2</sup>, 肖芬<sup>2</sup>, 林可尧<sup>2</sup>, 林超群<sup>2</sup>, 陈伯建<sup>1</sup>

(1. 国网福建省电力有限公司电力科学研究院, 福建 福州 350000;

2. 国网福建省电力有限公司, 福建 福州 350000)

**摘要:** 由于当前长期用电量预测方法难以解决变量选择问题, 造成用电量预测结果不准确, 为此将随机森林(RF)算法变量选择与长短期记忆(LSTM)网络回归两者结合, 设计基于RF变量选择与LSTM回归的长期用电量预测模型。采用RF方法对单一变量的重要性进行评估, 获取各项影响因素与用电量之间的相关系数, 然后选取其中取值较高的变量作为用电量预测的依据。结合RF变量选择结果, 分析动力系统理论, 采用收敛交叉映射方法研究用电量与工业发展水平、温度等因素之间的关系, 基于各因素之间的关系结合LSTM回归方法, 组建用电量预测模型, 实现长期用电量预测。研究结果表明, 与传统方法相比, 所设计模型的用电量预测精度与预测效率较高, 能够快速、准确地完成长期用电量预测, 表明该模型的应用价值更高。

**关键词:** 变量选择; 随机森林算法; 长短期记忆回归; 长期用电量; 预测模型

**中图分类号:** TP393 **文献标识码:** A **DOI:** 10.19457/j.1001-2095.dqed24072

## Long-term Electricity Consumption Forecast Model Based on RF Variable Selection and LSTM Regression

WU Xiangyu<sup>1</sup>, XUN Chao<sup>2</sup>, XIAO Fen<sup>2</sup>, LIN Keyao<sup>2</sup>, LIN Chaoqun<sup>2</sup>, CHEN Bojian<sup>1</sup>

(1. Electric Power Research Institute of State Grid Fujian Electric Power Co., Ltd., Fuzhou 350000, Fujian,

China; 2. State Grid Fujian Electric Power Co., Ltd., Fuzhou 350000, Fujian, China)

**Abstract:** Existing long-term electricity consumption prediction methods are difficult to solve the problem of variable selection, which leads to inaccurate prediction results of power consumption. Therefore, combining the radio frequency variable selection in random forest (RF) algorithm with long short-term memory (LSTM) regression in long-term and short-term memory networks, a long-term electricity consumption prediction model based on RF variable selection and LSTM regression was designed. RF method was used to evaluate the importance of a single variable, and the correlation coefficients between each influencing factors and electricity consumption were obtained. Then, the variable with higher value was selected as the basis of electricity consumption forecast. Combined with the selection results of RF variables, the theory of power system was analyzed, and the relationship between power consumption and industrial development level, temperature and other factors was studied by using convergence cross mapping method. Based on the relationship between various factors and the LSTM regression method, a prediction model of electricity consumption was established, and the long-term prediction of electricity consumption was realized. The results show that, compared with the traditional methods, the designed model has higher prediction accuracy and efficiency, can predict the long-term electricity consumption in the growing period quickly and accurately, and has high application value.

**Key words:** variable selection; random forest (RF) algorithm; long short-term memory (LSTM) regression; long-term power consumption; prediction model

用电量预测一直以来都是电网系统的核心研究内容, 用电量预测对于电力系统规划以及资源配置都具有十分重要的发展意义。在研究不

同用户用电属性的基础上进行用电量预测, 能够大力推动电力系统的发展<sup>[1]</sup>。

近年来, 相关专家针对该问题进行了大量研

**基金项目:** 国家电网有限公司科技项目资助(52022319003P)

**作者简介:** 吴翔宇(1991—), 男, 硕士, 工程师, Email: wxywx2010@163.com

究,丁业豪等<sup>[2]</sup>人设计了电力市场用电量需求分析预测模型,根据行业用电特性,给出电力市场用电量需求分析预测模型的总体架构,避免了数据孤岛的弊端。该方法可为电力系统发展提供数据依据,有利于提高电力系统对市场的分析与决策能力,但是该方法存在预测精度不高的问题。郑国和等<sup>[3]</sup>人提出基于多表融合数据的用户短期用电量预测方法,该方法利用通径分析计算影响用户用电量的日特征向量权重以及模糊相似矩阵,采用模糊聚类传递包法选择相似日,并将其作为样本训练支持向量机模型,从而完成对用电量的预测,但是该方法的预测效率不高。闵旭等<sup>[4]</sup>人提出了一种基于残差自回归方法的短期区域用电量预测方法,该方法运用残差自回归方法构建了时间序列预测模型,运用该模型对区域用电量进行预测,结果表明该方法能够有效提高短期区域用电量预测准确性,但是对长期用电量的预测精度有待提高。李海英等<sup>[5]</sup>人提出了一种基于即时学习差异化建模的用电量预测方法,通过K向量近邻算法(K-vector nearest neighbors, K-VNN)选取用电场景,选取的场景和预测时间具有相似性,然后建立一个回归预测模型,并结合模糊C均值方法对用电量的特征值进行聚类处理,根据聚类结果对用电量进行预测。结果表明,该方法在日用电量预测方面具有显著优势,但是在面向长期用电量预测问题时存在预测精度不高的问题。Ramos等<sup>[6]</sup>人提出了一种基于人工神经网络和增量学习的工业设施用电量消耗预测方法,该方法采用人工神经网络对样本进行训练,建立预测模型,结合增量学习方法对某工业设施16个月以来的数据进行处理,实现用电量预测。分析实验数值结果可知,该方法可以实现对长期用电量的有效预测,但是由于研究中需要处理的数据量较大,导致预测耗时较长。吕佳倍等<sup>[7]</sup>人提出了一种基于GDP-电能消费耦合关系的中长期电量预测方法,该方法在进行用电量预测之前,先对经济发展和电能消费之间的关系进行了分析,根据分析结果建立了用电量预测模型,并通过误差修正方法对模型进行调节。结果表明,该预测模型具有较高的解释能力,能够对用电量与经济之间的关系进行有效分析,但是其在预测精度方面的能力还有待提高。

以上方法重点针对短期用户用电量预测,对于长期用户量预测方面还有所欠缺,同时,存在

用电量预测结果准确性不高和耗时较长的问题,针对上述问题提出基于随机森林(random forest, RF)算法变量选择和长短期记忆(long short-term memory, LSTM)网络回归的用电量预测模型。将RF变量选择和LSTM回归结合,通过RF变量选择完成对随机特征变量属性的提取,降低不同决策树之间的相关性,起到提升分类结果准确性的作用,达到提高预测精度的目的。在此基础上,通过收敛交叉映射算法分析各因素与用电量之间的关系,获取各因素与用电量之间的相关系数,有效地解决了传统方法由于没有解决变量选择问题而导致的用电量预测不准确问题。将短期预测能力提升到对长时间序列的处理,从而实现对长期用电量的准确预测。实验结果表明,该模型能够有效提高用电量预测结果的准确性和预测效率,具有较高的实际应用价值。将其应用到实际场景中,如发电厂用电量预测、可再生能源开发、用户用电规划以及节能环保等领域具有重要的参考价值,可以通过用电量的预测以及用电量的分析,为降低用电能耗提供帮助。

## 1 预测模型构建

### 1.1 用电量影响变量选择

由于用电量产生的过程中,存在多种因素影响用电量,如温度、湿度等因素,这些因素在不同时间段影响用电量,使用电量具有实时变化性,同时,这些因素对后期用电量预测同样产生影响,因此,在构建长期用电量之前,运用RF算法选取影响变量。图1为随机森林算法原理图。

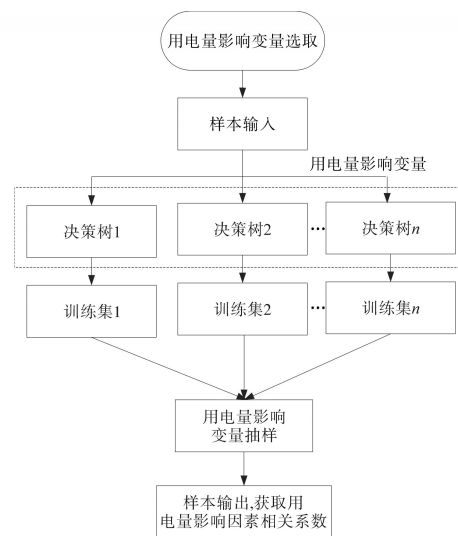


图1 随机森林算法原理图

Fig.1 Schematic diagram of the RF algorithm

由于单一因素不能充分反映用电量变化情况。因此,考虑到多因素影响问题,采用随机森林算法对用电量影响变量进行选取,首先,设置一个影响变量集合  $\partial = \{\partial_1, \partial_2, \dots, \partial_m\}$ , 其中,  $m$  表示变量类型。针对影响变量集合,建立多个独立的随机向量子集,由于在对预测样本进行输出时会产生一定的泛化误差,因此,在形成决策树之后,选取属性变量值,该值存在于子属性集合中,具体表达式为

$$P(x) = \operatorname{argmin} \sum_i^k I[p_i] \quad (1)$$

式中: $P(x)$ 为随机森林组合结果; $k$ 为分类树总数; $p_i$ 为单棵分类树; $I$ 为用电量影响变量集合中的随机因素。

不同决策树分别代表不同的训练集,这里的训练集是指包含不同影响变量的集合,在组建决策树的过程中,有多少个用电量影响变量就要组建多少个决策树,要组建多少个决策树就要形成多少个训练集,并且初始训练集中要包括不同的训练子集,可以用  $n$  进行表示。本文采用 bagging 技术训练初始训练集,训练后得到  $n$  个训练子集,训练子集的大小约初始训练集的 70%。为了保证各个训练子集中不同样本之间具有差异性,将采用随机抽样的形式进行抽样操作,并将抽样结果随机放回。

采用随机分组的形式对输出变量进行处理,并通过 CART 算法将不同组的变量形成一棵树,让其自由生长且不进行剪枝操作。在各个节点上,针对输入该节点的变量,重复上述操作过程,直至全部的阶段均为叶节点,则停止操作。

采用线性组合的方式对所有用电量影响变量集合中的随机因素进行处理,将处理结果作为输入变量组建随机森林算法<sup>[8-9]</sup>。输入  $L$  个变量进行随机抽取,得到新的线性组合,并随机选取  $L$  个变量,  $L$  个随机树  $k_i$ , 将其进行线性组合得到对应变量  $v$ :

$$v = P(x) \sum_{i=1}^L k_i \quad k_i \in [-1, 1] \quad (2)$$

通过以上操作则能够组建随机森林算法,采用投票的方式确定最后的输出结果,采用随机组建的  $N$  棵决策树分类处理测试样本,并整理不同的子树结果,结果中得票数量最多,即为分类的结果<sup>[10]</sup>。

在算法设计阶段,  $O_k(x)$  表示没有抽取过的数

据集,在该数据集中输入变量  $x$  的分类比例为

$$O_k(x) = \frac{\sum_k^L I[h_k(x) - y_j]}{\sum_k^L I[h_k(x)]} \quad (3)$$

式中: $h_k$ 为样本子集; $y_j$ 为测试样本; $x, y \in O_k(x)$ 。

将  $O_k(x)$  设定为随机森林算法准确分类的估计结果,则能够考察随机森林的强度和相关度两个变量<sup>[11]</sup>。

随机森林的强度  $s$  是指随机森林边缘函数的期望值:

$$s = \frac{1}{n} \left\{ \sum_{k=1}^n [1 - O_k(x)] \right\} \quad (4)$$

结合上述分析,将 Gini 系数作为变量重要性的核心,其取值越高,则说明该变量越重要,即

$$Gini_k = s \times 2k(1 - p_i) \quad (5)$$

以中国电力数据库中心为基础,结合式(5)的计算结果,将不同变量重要性进行排序,得到排序结果如表 1 所示。

表 1 用电量影响因素相关系数排序结果  
Tab.1 The ranking results of influencing factors of electricity consumption

变量类型	相关系数
工业发展水平	0.952
温度	0.923
湿度	0.917
农机数量及其用量	0.910
第三产业发展水平	0.901
人均国内市场总值	0.894
国内生产总值	0.853
能源消耗增量	0.801
天气因素	0.715

根据表 1 中的数据可知,用电量与工业发展水平的相关系数最高,说明经济发展与进步会带来用电量的提升,温度和湿度等气候条件也会对用电量带来一定程度的影响,同时,作为农业发展的关键设备,农业机械的数量及其用电量也是影响地区用电量的关键因素。通过上述分析可知,影响用电量的因素具有多样性,需要选取相关系数取值较高的变量作为用电量预测的依据。

### 1.2 基于 LSTM 回归的长期用电量预测模型

以单一变量重要性评估结果为基础,采用收敛交叉映射算法对用电量和温度、工业发展水平等因素之间的关系进行分析。收敛交叉映射算法的核心思想为:一个确定性的动力系统即使是

混沌的,也具有长期预测的能力<sup>[12-13]</sup>,因此,能够用于因果识别。假设  $X = \{x_t\} T_{t=1}$  和  $Y = \{y_t\} T_{t=1}$  代表两个不同的用电量变化时间序列,基于 Takens 原理,通过时间延迟坐标方法对空间进行重构,从而得到重构流形,其与拓扑等价:

$$M_x = \{x_t\} T_{t=r} \quad (6)$$

$$M_y = \{y_t\} T_{t=r} \quad (7)$$

其中

$$x_t = \{x_t, x_{t-\tau}, x_{t-2\tau}, \dots, x_{t-(f-1)\tau}\} \quad (8)$$

$$y_t = \{y_t, y_{t-\sigma}, y_{t-2\sigma}, \dots, y_{t-(q-1)\sigma}\} \quad (9)$$

其中

$$r = \max [1 + (f - 1)\tau, 1 + (q - 1)\tau] \quad (10)$$

式中:  $f$  为  $X$  的嵌入维数;  $q$  为  $Y$  的嵌入维数;  $\tau$  为与  $X$  对应的延迟时间;  $\sigma$  为与  $Y$  对应的延迟时间。

假设  $X$  是  $Y$  的因,关于  $X$  的全部信息都包含在  $Y$  的重构流形中,通过  $Y$  的重构流形能够估算出  $X$  的情况。

重构空间大小为  $l$  的子集,  $M'_x$  代表与  $X$  对应的影子流形;  $M'_y$  代表与  $Y$  对应的影子流形。收敛交叉映射算法需要判定对应的位置信息是否能够更好地计算对应估计点之间的关系。基于 LSTM 回归的长期用电量预测模型更加适用于长时间序列的处理, LSTM 回归主要采用 BPTT 进行参数求解。

通过上述分析,结合 LSTM 回归方法<sup>[14]</sup>,组建用电量预测模型,以实现用户长期用电预测,图2为收敛交叉映射算法与 LSTM 回归方法结合下的长期用电量预测流程图。

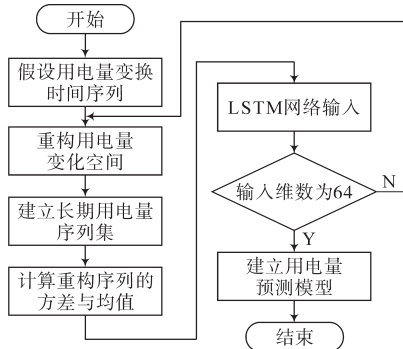


图2 长期用电量预测流程图

Fig.2 Flow chart of long-term electricity consumption forecast

根据图2可知,本文所提的长期用电量预测模型具体的操作步骤如下:

- 1) 组建长序列集,即长期用电量变化序列;
- 2) 对重构序列的均值和方差进行计算;
- 3) 将重构序列、均值以及方差作为 LSTM 网络输入,设定输入维数为 64;

- 4) 设定输出层维数为 1,损失函数为  $L^2$ ;
- 5) 结合 LSTM 回归方法<sup>[15]</sup>,组建长期用电量预测模型,实现用户长期用电量预测。

## 2 仿真实验

为了验证所设计的基于 RF 变量选择与 LSTM 回归的长期用电量预测模型可行性与有效性,在 Intel Core i7-4710MQ, 2.50 GHz, 8 GB RAM, Windows 10 环境下进行实验测试。

### 2.1 实验数据选取

由于数据在变化过程中会产生振荡现象,那么在实验中就需要足够多的数据,因此,以中国电力数据库中心为实验数据来源,在该数据库中选取某地区 2020 年一整年的实际用电量数据作为实验分析对象,该地区用电量的变化趋势如图 3 所示。




图3 实验地区2020年用电量月分布

Fig.3 Monthly distribution of electricity consumption in the experimental area in 2020

分析图3可知,受季节、温度等影响该地区的用电量呈现季节性特点。以图3中的数据为基础,采用文献[2]中的电力市场用电量需求分析预测模型、文献[3]中基于多表融合数据的用户短期用电量预测方法与所设计模型对该地区 12 个月的用电量进行预测,并运用统计软件 SAS 对该地区长期用电量进行处理。

### 2.2 实验结果与分析

为了验证预测结果的准确性,以下实验分别对比在不同温度下,各个预测方法的相对误差变化情况,具体的实验对比结果如下图4所示。其中,相对误差的计算公式为

$$F = \frac{e}{e_i} \times 100\% \quad (11)$$

式中:  $e$  为绝对误差;  $e_i$  为实际用电量。

分析图4中的实验结果可知,不同预测方法的相对误差会随着温度的变化而变化,但是在 6 月份之前,变化幅度并不是十分明显,从 6 月份开




图4 不同方法的预测结果

Fig.4 Forecast results of different methods

始,随着气温升高以及冬天供暖季的到来,用电量会发生较大变化,而随着用电量数据的增加,预测结果的相对误差也会随之加大。但是与其他预测方法相比,所设计模型的相对误差明显较低,这说明所设计模型能够取得十分满意的预测结果。所提模型在实际研究的过程中,结合随机森林算法有效解决了变量选择问题,促使整个模型的预测精度得到有效提升。

为了测定不同用户用电时间和用户用电量预测精度之间的关系,进行实验分析,实验结果如图5所示。




图5 用户用电时长和预测精度之间的关系对比结果

Fig.5 Comparison results of the relationship between user power consumption time and prediction accuracy

分析图5中的实验数据可知,在实验初期,所设计模型的预测精度与文献[2]方法及文献[3]方法的预测精度相差很小,但是随着用电时长的持续增加,所设计模型的预测精度大幅度提升。由此可见,所设计模型更加适用于长期用电量预测。另外这三种方法都适用于短期用电量预测。主要是由于RF变量选择的应用,所设计模型有效提升了长期预测精度。

为了测定不同方法的预测效率,对其进行实验测定,所得结果如下表2所示。

表2 不同方法的预测效率对比(%)

Tab.2 Comparison of predictive efficiency of different methods(%)

实验序号	所设计模型	文献[2]方法	文献[3]方法
1	97.39	95.85	90.33
2	96.74	96.69	94.74
3	95.58	94.74	93.08
4	98.44	92.25	91.66
5	97.96	93.63	89.59
6	96.23	95.14	87.64
7	98.85	94.25	90.85
8	99.14	96.11	92.27
9	99.13	95.96	93.01
10	99.02	94.74	94.55
11	97.42	93.65	93.78
12	99.74	92.47	92.02
13	98.52	92.66	93.96

分析上表2中的实验数据可知,与现有方法相比,所设计模型的预测效率明显更高,说明所设计模型能够实现对长期用电量的快速预测,这是源于RF变量选择问题得到了有效解决,使模型的预测效率得到了改善。所设计模型通过随机森林方法选取重要性变量,再采用收敛交叉映射方法分析用电量和其影响因素之间的关系,从而实现长期用电量预测。

综上实验结果可知,虽然传统单一预测方法同样能够达到一定的预测精度,但是从不同角度分析,所设计模型的预测结果更加可靠、更加合理、更加全面,可以为电力系统的供电决策提供决策参考。

### 3 结论

针对传统用电量预测模型存在预测精度以及预测效率较低等问题,结合RF变量选择与LSTM回归,组建一种基于RF变量选择与LSTM回归的长期用电量预测模型。研究结果显示,所提模型能够高精度、高效率地实现长期用电量预测。未来阶段,将重点针对以下内容展开研究:在实验测试过程中,并没有涉及预测成本方面的内容,如企业电力运行与规划成本、电力负荷等内容,由于时间以及环境等多方面因素的限制,导致所组建预测模型仍然存在不足,后续将进一步对其进行完善。

#### 参考文献

[1] 乔黎伟,王静怡,郭炜,等. 基于随机森林算法的中短期用电量预测[J]. 电力科学与技术学报,2020,35(2):150-156.

QIAO Liwei, WANG Jingyi, GUO Wei, et al. Medium and short-term electricity demand prediction based on random forests algorithm[J]. Journal of Electric Power Science and Technology, 2020, 35(2): 150-156.

[2] 丁业豪, 麦琪. 电力市场用电量需求分析预测模型研究[J]. 电测与仪表, 2017, 54(14): 14-23.  
DING Yehao, MAI Qi. Research on power market electricity demand analysis and forecasting model[J]. Electrical Measurement & Instrumentation, 2017, 54(14): 14-23.

[3] 郑国和, 贺民, 郑瑞云, 等. 基于多表融合数据的用户短期用电量预测[J]. 电力系统及其自动化学报, 2019, 31(3): 146-150.  
ZHENG Guohe, HE Min, ZHENG Ruiyun, et al. Short-term electricity consumption forecasting based on multi-meter fusion data[J]. Proceedings of the CSU-EPSA, 2019, 31(3): 146-150.

[4] 闵旭, 叶青, 蔡高琰. 基于残差自回归方法的短期区域用电量预测[J]. 技术经济, 2019, 38(6): 119-124.  
MIN Xu, YE Qing, CAI Gaoyan. Short-term regional electricity demand forecasting based on residual autoregression [J]. Technology Economics, 2019, 38(6): 119-124.

[5] 李海英, 杨冰芳, 孙伟卿. 基于即时学习差异化建模的用电量预测方法[J]. 电力系统及其自动化学报, 2020, 32(3): 14-19.  
LI Haiying, YANG Bingfang, SUN Weiqing. Lazy learning based diversity models for electricity consumption forecasting [J]. Proceedings of the CSU-EPSA, 2020, 32(3): 14-19.

[6] RAMOS D, FARIA P, VALE Z, et al. Industrial facility electricity consumption forecast using artificial neural networks and incremental learning[J]. Energies, 2020, 13(18): 1-18.

[7] 吕佳倍, 孙伟卿, 韩冬, 等. 基于GDP-电能消费耦合关系的中长期电量预测[J]. 电网与清洁能源, 2019, 35(1): 1-7, 15.  
LÜ Jiabei, SUN Weiqing, HAN Dong, et al. Medium and long term electricity forecasting based on GDP-electricity consumption coupling[J]. Power System and Clean Energy, 2019, 35(1): 1-7, 15.

[8] 何耀耀, 刘瑞, 撤奥洋. 基于实时电价与支持向量分位数回归的短期电力负荷概率密度预测方法[J]. 中国电机工程学报, 2017, 37(3): 768-775.  
HE Yaoyao, LIU Rui, HAN Aoyang. Short-term power load probability density forecasting method based on real time price and support vector quantile regression[J]. Proceedings of the CSEE, 2017, 37(3): 768-775.

[9] 彭喜英, 李博文. 基于随机森林回归算法的感应电机驱动控制[J]. 电测与仪表, 2018, 55(4): 61-69.  
MI Zhichang, REN Chunguang, HAN Xiaoqing, et al. Design of secondary voltage regulation system of DC micro-grid[J]. Electrical Measurement & Instrumentation, 2018, 55(4): 61-69.

[10] 腾腾, 赵治华. 电磁发射系统监测量预测方法[J]. 电工技术学报, 2018, 33(22): 5233-5243.  
TENG Teng, ZHAO Zhihua. The prediction method of monitoring quantities of electromagnetic emission system[J]. Transactions of China Electrotechnical Society, 2018, 33(22): 5233-5243.

[11] 张林, 刘继春, 马靖宇, 等. 基于函数型特征数据的光伏短期功率预测方法[J]. 电气传动, 2021, 51(12): 66-73.  
ZHANG Lin, LIU Jichun, MA Jingyu, et al. Short term power forecasting method of photovoltaic based on functional characteristic data[J]. Electric Drive, 2021, 51(12): 66-73.

[12] 苏适, 周立栋, 万筱钟, 等. 计及气象因素的用电负荷短期分时分类预测模型与方法[J]. 电力建设, 2017, 38(10): 76-83.  
SU Shi, ZHOU Lidong, WAN Xiaozhong, et al. Time-sharing and classified prediction model for short-term load considering meteorological factors[J]. Electric Power Construction, 2017, 38(10): 76-83.

[13] 何峰, 钟婷, 谭貌. 基于二次EEMD的工业电能需求多步预测[J]. 计算技术与自动化, 2021, 40(3): 72-77.  
HE Feng, ZHONG Ting, TAN Mao. Multi-step forecasting of industrial electrical power demand based on twice ensemble empirical mode decomposition[J]. Computing Technology and Automation, 2021, 40(3): 72-77.

[14] 吴佳懋, 李艳, 符一健. 基于粗糙集-混沌时间序列Elman神经网络的短期用电量预测[J]. 电力系统保护与控制, 2019, 47(3): 29-36.  
WU Jiamao, LI Yan, FU Yijian. Short-term power consumption prediction based on rough set chaotic time series Elman neural network [J]. Power System Protection and Control, 2019, 47(3): 29-36.

[15] 朱尤成, 王金荣, 徐坚. 基于深度学习的中长期风电发电量预测方法[J]. 广东电力, 2021, 34(6): 72-78.  
ZHU Youcheng, WANG Jinrong, XU Jian. Medium and long term wind power generation forecasting method based on deep learning[J]. Guangdong Electric Power, 2021, 34(6): 72-78.

gy storages in a DC microgrid with communication delay[J]. IEEE Transactions on Smart Grid, 2020, 11(3): 2033-2042.

收稿日期: 2021-05-27

修改稿日期: 2021-10-17

收稿日期: 2021-01-03

修改稿日期: 2021-01-21

~~~~~  
(上接第 62 页)