基于D-S证据理论的光伏发电量预测

结合北京地区实际环境因素和某光伏并网发电系统运行数据，对光伏系统发电功率进行预测。利用决策树算法，设环境温度、组件温度和辐射量为系统特征，发电量为决策标签，得到特征的分类主次关系，进而将原始数据划分为数个集合作为D-S证据理论中的证据。提取集合中的权重系数并将其等效为证据理论中的基本信任分配函数，并进行证据的融合，最终得到预测结果。最后对比分析经过D-S证据理论融合的预测数据和平均值法得到的预测结果，并计算分析绝对误差和相对误差，验证了D-S证据理论预测的准确性，所预测的光伏发电功率可指导光伏并网发电生产。

李英姿[1] 曾万昕[1] 戴 玉[2] 郭俊杉[3] 胡亚伟[4]/1.北京建筑大学电气与信息工程学院 2.中国建筑设计院有限公司 3.国网北京市电力公司房山供电公司 4.北京电力工程有限公司

李英姿/教授

关键词/Keywords

决策树·
光伏发电量·
D-S证据理论·
组件温度·
环境温度·
辐射量·

0 引言

截至2017年末，我国光伏装机容量达130 GW，是光伏新增容量首次超过火电容量(46 GW)的年份。据国家能源局估计，2017年我国风电和光伏发电的总限电量为49.2 TW·h。这意味着可再生能源发电资产所有者至少因为限电损失了307亿元人民币。要提高光伏发电的使用率，降低限电率，就要解决好光伏功率预测问题。目前的发电功率预测手段可以被分为四大类，即基于数值天气预报或太阳辐照度预测的物理原理预测法，以回归分析时间序列为主的统计预测法，包括灰色模型、马尔科夫的不确定性理论预测法，利用神经网络、支持向量机的智能预测法。

光伏发电系统受环境以及其组件特性等多因素的影响，其出力有着随机性的特点。要综合考虑预测时刻的气象环境等因素和历史光伏发电数据。传统的预测方法很难对其进行精准的预测，因此研究新的预测方法成为必然[1]。目前比较常用的预测方法有数值天气预报法、灰色理论和BP神经网络等[2]。数值天气预报的主要思想是通过物理模型结合数值天气预报预测有效的辐射量，进而预测光伏发电量[3]，这种方法依赖于其他的数据采集装置；灰色系统理论是以针对既不是完全明确也不是完全未知的系统进行建模研究，进而来进行预测[4]，这一预测方法不要求数据的完备，但是预测准确度会受到限制；基于BP算法的多层前馈神经网络是一种智能方法，现在得到广泛应用[5]，但是可能出现局部最优解问题。

本文将D-S证据理论应用于决策树算法，并结合2014年1月1日~2017年12月31日北京地区的天气状况与北京市西城区某5.3 kW光伏并网发电系统的实际检测数据，用2014～2016年包含各个影响因素的光伏系统实测数据作为决策树的输入，分类得出的数据组再利用D-S证据理论进行数据融合，得到2017年预测结果。本文使用Python计算机工具，并主要使用Pandas和Numpy函数库编程实现运算。针对预测结果进行误差分析，针对每日不同时刻和同一时刻不同日期进行对比分析，并最终得出结论。

1 基本理论

1.1 决策树理论

决策树[6-7]是一种常见的机器学习方法，作为分类工具被广泛使用。本文将

决策树应用于对光伏发电系统的历史数据及环境参数的分类处理中，将光伏发电功率作为分类标签，环境影响因素作为条件属性分析影响因素的重要程度，并得到分类结果。

决策树对历史数据分类的步骤为如下。

1）计算信息熵。信息熵是度量样本集合纯度最常用的一种指标，设符号x_i的信息被定义为$l(x_i)=\log_2 p(x_i)$，其中$p(x_i)$为这一信息的概率。则信息熵为

$$H=-\sum_{i=1}^{n}p(x_i)\log_2 p(x_i) \tag{1}$$

式中，n为类别的数量。

2）划分数据集。根据不同的特征计算得到的信息熵，比较之后剔除掉对数据集纯度提成最大的特征。

3）建立决策树。循环上述步骤直到分析完每一个特征，并绘图建立决策树。

1.2 D-S证据理论

（1）D-S证据基本理论

D-S证据理论[8]建立了命题和结论一一对应的关系，用D-S证据理论合成规则代替了贝叶斯公式来更新信任函数。D-S证据理论用“识别框架”表示所感兴趣的命题集，若识别框架在集函数m:2^{Θ}→[0,1](其中，2^{Θ}为Θ的幂集)上满足

$$\begin{cases} m(\varnothing)=0 \\ \sum m(A)=1 \\ A\subset\Theta \end{cases} \tag{2}$$

式中，m为框架Θ上的基本概率指派函数或基本可信度分配；若∀A⊆Θ，$m(A)$称为A的基本可信数；若$m(A)>0$，则称所有满足该条件的集合A为m的焦点元素，并将与基本可信度分配m相对应的信度函数记为Bel。

（2）D-S证据理论合成法则

D-S合成法则是一个反映证据联合作用的法则。若证据不是完全冲突的，则可以利用 D-S合成法则计算出一个新的信任函数。

设Bel_1、Bel_2是同一个识别框架上两个信任函数，m_1、m_2分别为其对应的基本可信度分配，对应焦元分别为A_i和B_j。设$K=\sum_{A_i\cap B_j=A}m_1(A_i)m_2(B_j)<1$，则D-S合成法则为

$$m(A)=\begin{cases}\dfrac{\sum_{A_i\cap B_j=A}m_1(A_i)m_2(B_j)}{1-K} & A\neq\varnothing \\ 0 & A=\varnothing\end{cases} \tag{3}$$

式中，K为两个证据的冲突程度，其值越大表示两个证据冲突越大，K=1表示两个证据矛盾不能合成。

$1/(1-K)$称为归一化因子，其作用是避免证据合成时空集得到非零的概率。若待合成的函数多于两个，则可以采用上述方法将前一步合成结果与下一个函数进行合成，直至所有函数合成完毕。

（3）基于证据理论的权重融合

1）权重提取。首先要提取权重，对上述决策树分类得到的数组命名为D_j，由数个数组组成模型的识别框架Θ={D_1, D_2, …, D_n}($n>0$)。设每一个时刻的环境参数和光伏发电功率数据就是一条证据。假设有s个时刻的数据，就有证据集。表示证据支持相应数组d_j的程度，其中i=1, …, s, j=1, …, n。对于模型识别框架，数据的相对误差越小，相应的权值应该越大。本文权值的计算方法为

$$w_i(d_j)=\frac{1/\varepsilon_i(d_j)}{\sum_{j=1}^{n}[\varepsilon_i(d_j)]} \tag{4}$$

$$\varepsilon_i(d_j)=\frac{\left|x_i-x_i^{'}(d_j)\right|}{\left|x_i\right|} \tag{5}$$

式中，$\varepsilon_i(d_j)$为第i个时刻来自第j个数据组的相对误差；x_i为第i个时刻的实测值；$x_i^{'}(d_j)$为上一个时刻的实测值计算。

2）权重融合。在发电量预测融合模型中，对于预测准确度高的预测值赋予较大的权重，对于预测准确度低的预测值赋予较小的权重，此过程类似于证据理论中基本可信度函数的分配，通过类比的思想，模型权重可视为证据理论的基本信度值。

对于四个决策树模型预测值$\hat{d}_1$、$\hat{d}_2$、$\hat{d}_3$和$\hat{d}_4$，

对应权重分别为w_1、w_2、w_3和w_4，在识别框架$\Theta=\{\hat{y}_1, \hat{y}_2, \hat{y}_3, \hat{y}_4\}$上建立基本信任分配函数$m(\hat{d}_i)$，其对应的信度值为$m(\hat{d}_i)=w_i(i=1, 2, 3, 4)$。假设四个发电量预测值所对应的信度值为$m(\hat{d}_i)=(i=1, \cdots, s; j=1, \cdots, n)$。假设以五个时刻进行合成，最终的到的信度值为$m_4(\hat{d}_1)$、$m_4(\hat{d}_2)$、$m_4(\hat{d}_3)$和$m_4(\hat{d}_4)$。假设第五个时刻的发电量预测值为$\hat{d}_1^5$，$\hat{d}_2^5$，$\hat{d}_3^5$，$\hat{d}_4^5$，则最终合成结果表示为[9-12]

$$\hat{d}_4 = m_4(\hat{d}_1)\hat{d}_1^5 + m_4(\hat{d}_2)\hat{d}_2^5 + m_4(\hat{d}_3)\hat{d}_3^5 + m_4(\hat{d}_4)\hat{d}_4^5 \quad (6)$$

（4）基于D-S证据理论的光伏发电量预测方法

基于D-S证据理论的光伏发电量预测的计算步骤如下。

1）步骤1。根据日期时间索引，确定历史数据的预测空间Data1。

2）步骤2。以待预测时刻的环境条件参数建立决策树分类原始数据D_0，以发电功率P作为决策标签，环境温度T_1、组件温度T_2、辐射量R和环境湿度W作为属性条件，进行决策树分类，并得到四个预测矩阵d^1、d^2、d^3和d^4。设每个矩阵中有s个时刻，则有

$$d^i = \begin{bmatrix} d_1, r_1, t_{1.1}, t_{2.1}, w_1, p_1 \\ d_2, r_2, t_{1.2}, t_{2.2}, w_2, p_2 \\ \vdots \vdots \vdots \quad \vdots \quad \vdots \quad \vdots \\ d_s, r_s, t_{1.s}, t_{2.s}, w_s, p_s \end{bmatrix} \quad (7)$$

3）步骤3。对四个矩阵进行数据预处理，删掉粗大误差，并依据时间最近原则将这四矩阵补齐成为行相等的矩阵$D^{1'}$、$D^{2'}$、$D^{3'}$和$D^{4'}$。

4）步骤4。取出上述矩阵中的发电量预测值，根据式（3）计算出权值矩阵$\boldsymbol{M}$。

5）步骤5。迭代计算出权值矩阵最终权值。

$$m_j(\hat{d}_i):\{m_s(\hat{d}_1),\ m_s(\hat{d}_2),\ \cdots,\ m_s(\hat{d}_n)\} \quad (8)$$

6）步骤6。根据式（6）迭代计算出最终预测值。

图1为基于D-S证据理论的光伏发电量预测流程图。

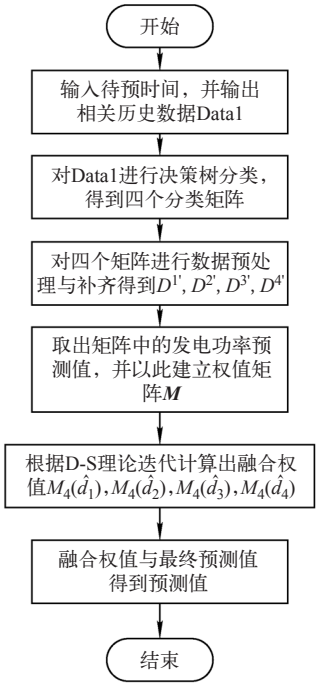

图1 基于D-S证据理论的光伏发电量预测流程图

2 算例分析

以北京市西城区某5.3 kW光伏并网发电实验设备2014~2017年的实际环境参数和设备运行数据为依据。

2.1 案例数据

表1为待预测时刻t_0（以2017年10月24日15:25为例）的环境和设备数据。

表1 2017年10月24日15:25的环境和设备数据

日期	辐射量 R /(W/m²)	环境湿度 W (%)	组件温度 T_1/℃	环境温度 T_2/℃
2017-10-24 15:25	82.59	42.01	19.80	18.78

表2为待预测时刻前1 h的历史数据。在此表中确定辐射量最接近待预测时刻的一条数据，以此来确定最接近真值的功率值。

表2 待预测时刻前1 h数据

时间	辐射量 R/(W/m²)	环境湿度 W (%)	组件温度 T_1/℃	组件温度 T_2/℃	发电功率 P_0/kW
14:25	296.89	42.01	26.03	19.96	0.77
14:30	275.77	42.01	25.81	19.85	0.74
14:35	251.54	42.02	25.47	19.84	0.70
14:40	231.39	42.02	24.95	19.74	0.65
14:45	210.77	42.02	24.12	19.68	0.60
14:50	203.29	42.02	23.90	19.69	0.57
14:55	182.83	42.01	23.39	19.58	0.53
15:00	131.29	42.01	22.45	19.49	0.49
15:05	113.32	42.01	21.26	19.25	0.47
15:10	107.49	42.01	20.41	19.05	0.44
15:15	100.18	42.02	19.77	18.96	0.41
15:20	90.85	42.01	19.39	18.83	0.36

表2中得到功率接近值 $\tilde{P}_0$=0.36 kW，再由误差标准得到在 $\tilde{P}_0$ 的15%范围内为合格的功率值，以此标准来建立决策树。搜索前三年的表格得到的决策表格如表3所示。由于该表格行数达到两万余行，本文仅部分展示。

表3 决策树决策分类表格

日期	辐射量 R（W/m²）	环境湿度 W（%）	组件温度 T_1/℃	环境温度 T_2/℃
2014-10-09 12:00	302.87	42.012	28.34	22.17
2014-10-09 12:05	302.41	42.007	28.26	22.28
2014-10-09 12:10	301.38	42.012	28.56	22.38
2014-10-09 12:15	298.36	42.012	28.65	22.41
2014-10-09 12:20	297.01	42.012	28.38	22.23
2014-10-09 12:35	290.65	42.012	28.47	22.60
⋮	⋮	⋮	⋮	⋮
2016-11-08 15:40	43.73	42.003	10.81	11.60
2016-11-08 15:45	38.31	42.008	10.58	11.50
2016-11-08 15:50	32.23	42.013	10.35	11.46
2016-11-08 15:55	27.19	42.017	10.03	11.34
2016-11-08 16:00	22.18	42.017	9.71	11.16

2.2 决策树计算

表格以最终功率预测规范的功率值为标签，逐步进行决策树分类计算，其分别将辐射量在待预测时刻10 W/m²，组件温度和环境温度在待预测时刻2 ℃，湿度在1%范围内。决策树决策分类图如图2所示。

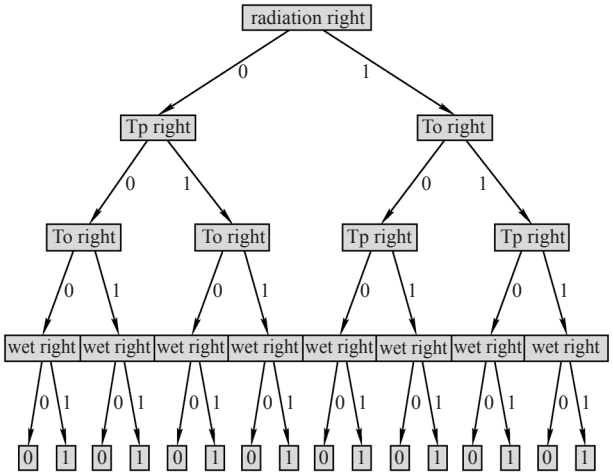

图2 决策树分类图

每个时刻的预测表格都不尽相同，但是经过多次决策分类发现辐射量为主要条件，而环境湿度的数据对决策分类并没有太大影响，于是按照辐射、量组件温度和环境温度这三个条件的不同取值得到四个矩阵。如表4所示。

表4 决策树分类表格

决策条件	辐射量 R/（W/m²）	组件温度 T_1/℃	环境温度 T_2/℃
111	在范围内	在范围内	在范围内
110	在范围内	在范围内	在范围外
101	在范围内	在范围外	在范围内
100	在范围内	在范围外	在范围外

将得到的矩阵按照时间最近原则补齐，得到下列四个数表，如表5所示。

表5 决策树处理结果

决策条件	日期	时间	辐射量 R/（W/m²）	组件温度 T_1/℃	环境湿度 W（%）	发电功率 P_0/kW	发电功率是否在范围内
	2016-10-26	15:10:00	85.952	18.239	17.013	0.358	1
	2016-10-25	15:40:00	77.378	18.870	18.243	0.292	0
111	2016-10-25	15:35:00	87.120	19.241	18.459	0.355	1
	2016-10-25	15:20:00	76.709	19.858	18.800	0.279	0
	2016-10-23	15:30:00	77.397	18.119	17.423	0.325	1
	2016-10-18	14:20:00	83.791	21.913	20.387	0.384	1
	2016-10-18	14:25:00	74.153	21.650	20.433	0.323	1
110	2015-11-02	15:10:00	78.734	22.952	20.370	0.469	0
	2015-11-02	15:15:00	73.883	21.491	20.191	0.434	0
	2015-10-19	15:40:00	83.883	21.487	20.604	0.314	1
	2016-10-26	15:15:00	73.791	17.504	16.735	0.314	1
	2014-11-04	15:15:00	87.486	18.533	16.393	0.422	0
101	2014-11-04	15:20:00	80.965	17.560	16.387	0.368	1
	2014-10-28	15:05:00	80.391	19.667	16.338	0.315	1
	2014-10-27	15:25:00	82.969	18.138	16.346	0.368	1
	2016-11-08	15:10:00	72.688	12.213	12.091	0.270	0
	2016-11-08	15:05:00	76.809	12.777	12.300	0.315	1
100	2016-11-08	15:00:00	80.320	13.387	12.478	0.370	1
	2016-11-08	14:55:00	86.021	14.491	12.483	0.459	0
	2016-11-06	14:00:00	87.832	12.136	11.576	0.434	0

2.3 D-S证据融合计算

首先得到功率预测矩阵

$$P_1=\begin{bmatrix}P_{11} & P_{12} & P_{13} & P_{14}\\ P_{21} & P_{22} & P_{23} & P_{24}\\ P_{31} & P_{32} & P_{33} & P_{34}\\ P_{41} & P_{42} & P_{43} & P_{44}\\ P_{51} & P_{52} & P_{53} & P_{54}\end{bmatrix}=\begin{bmatrix}0.358 & 0.384 & 0.314 & 0.270\\ 0.292 & 0.323 & 0.422 & 0.315\\ 0.355 & 0.469 & 0.367 & 0.370\\ 0.279 & 0.434 & 0.315 & 0.459\\ 0.325 & 0.314 & 0.368 & 0.434\end{bmatrix} \tag{9}$$

由上可知功率近似值为 $\tilde{P}_0$=0.36 kW，由此计算上述矩阵的相对误差（此处提取功率值计算），即

$$\varepsilon(P_1)=\frac{\left|P_1-\tilde{P}_0\right|}{\left|P_1\right|}$$

$$\varepsilon(P_1)=\begin{bmatrix}\varepsilon_{11} & \varepsilon_{12} & \varepsilon_{13} & \varepsilon_{14}\\ \varepsilon_{21} & \varepsilon_{22} & \varepsilon_{23} & \varepsilon_{24}\\ \varepsilon_{31} & \varepsilon_{32} & \varepsilon_{33} & \varepsilon_{34}\\ \varepsilon_{41} & \varepsilon_{42} & \varepsilon_{43} & \varepsilon_{44}\\ \varepsilon_{51} & \varepsilon_{52} & \varepsilon_{53} & \varepsilon_{54}\end{bmatrix}=\begin{bmatrix}0.013\,3 & 0.056\,4 & 0.136\,9 & 0.256\,1\\ 0.195\,3 & 0.111\,5 & 0.162\,1 & 0.133\,4\\ 0.022\,6 & 0.290\,4 & 0.012\,5 & 0.017\,8\\ 0.233\,3 & 0.194\,9 & 0.134\,0 & 0.263\,4\\ 0.106\,6 & 0.136\,6 & 0.013\,0 & 0.195\,3\end{bmatrix} \tag{10}$$

进而计算出权值矩阵 $m(\hat{P}_i)=w_i(i=1,2,3,4)$

$$m(\hat{P}_j)=\frac{1/\varepsilon(\hat{P}_j)}{\sum_{j=1}^{n}[\varepsilon(\hat{P}_j)]}$$

$$w=\begin{bmatrix}w_{11} & w_{12} & w_{13} & w_{14}\\ w_{21} & w_{22} & w_{23} & w_{24}\\ w_{31} & w_{32} & w_{33} & w_{34}\\ w_{41} & w_{42} & w_{43} & w_{44}\\ w_{51} & w_{52} & w_{53} & w_{54}\end{bmatrix}=\begin{bmatrix}0.358\,4 & 0.383\,7 & 0.313\,5 & 0.270\,2\\ 0.292\,3 & 0.322\,8 & 0.422\,1 & 0.314\,8\\ 0.355\,0 & 0.468\,7 & 0.367\,8 & 0.369\,7\\ 0.278\,5 & 0.434\,0 & 0.314\,6 & 0.459\,0\\ 0.324\,5 & 0.313\,7 & 0.368\,0 & 0.434\,2\end{bmatrix} \tag{11}$$

逐一合成权值得到最终权值数组为

$$w(\hat{P}_i)=[m(\hat{P}_1),m(\hat{P}_2),\cdots,m(\hat{P}_4)]$$

$$w(\hat{P}_i)=[0.670\,1\ 0.025\,8\ 0.246\,9\ 0.057\,2] \tag{12}$$

与最后的预测值合成得到预测结果为

$$\begin{aligned}\hat{P}_4&=m_4(\hat{P}_1)\hat{P}_1^5+m_4(\hat{P}_2)\hat{P}_2^5+m_4(\hat{P}_3)\hat{P}_3^5+m_4(\hat{P}_4)\hat{P}_4^5\\&=0.670\,1\times0.325+0.025\,8\times0.314+0.246\,9\times\\&\quad 0.368+0.057\,2\times0.434=0.341\,3\end{aligned} \tag{13}$$

则2017年10月24日15:25的预测结果为 $\tilde{P}_0$=0.341 3 kW，实测值为P=0.327 3 kW。

3 误差分析

根据以上预测方法对一天中的不同时刻进行预测，选取的时间为2017年10月24日9:00~16:00的每个整点时刻。如图3所示。

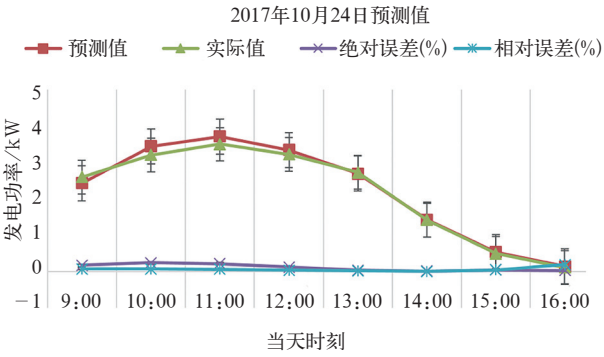

图3 2017年10月24日预测及误差分析图

从图3中可以看出，10:00和11:00的误差相对较大，最大的绝对误差为11:00的0.214 5 kW，最大相对误差为9:00的7.8%，均能达到规范要求。将通过D-S证据理论融合的数据与算数平均值的预测数据进行分析比较，并给出各自的误差计算如表6、表7所示。

表6 不同时刻预测结果

时刻	实测功率/kW	D-S融合预测功率/kW	绝对误差/kW	相对误差(%)
9:00	2.598 5	2.426 7	0.171 9	6.613 4
10:00	3.205 2	3.439 8	−0.234 6	−7.319
11:00	3.498	3.712 5	−0.214 5	−6.133
12:00	3.225 3	3.341 5	−0.116 2	−3.602
13:00	2.721 6	2.686 8	0.034 8	1.278 7
14:00	1.413 2	1.418 1	−0.004 9	−0.347
15:00	0.489 7	0.534 4	−0.044 8	−0.914 1

表7 2017年10月24日平均预测结果

时刻	实测功率/kW	D-S融合预测功率/kW	绝对误差/kW	相对误差(%)
9:00	2.598 5	2.923 6	−0.325 1	−12.511
10:00	3.205 2	3.362 1	−0.156 9	−4.894
11:00	3.498	3.756 5	−0.258 5	−7.39
12:00	3.225 3	3.349 3	−0.124	−3.844
13:00	2.721 6	2.733 5	−0.012	−0.44
14:00	1.413 2	1.372	0.041 2	2.918 1
15:00	0.489 7	0.567 9	−0.078 2	−15.973

针对10月的气候特征，上午11:00应该是辐射量较大的时刻，然而可能会出现辐射量很小的时刻，这种情况与天气有关。对比经过数据融合的数据与平均值的数据可得，经过数据融合的预测绝对误差和相对误差均优于平均值预测数据，而且在规定的预测范围内保证了预测准确度，并具

有更高的稳定性。

4 结束语

本文采用的预测方法，是基于不确定性理论的D-S证据理论针对光伏发电受环境、设备因素等不确定因素影响的发电量预测，采用了数据挖掘中的决策树算法，全面综合历史数据，利用Python程序实现算法，得到预测结果。

从预测结果与误差分析来看，所采用的预测方法具有一定的预测准确度，满足NB/T 32011—2013《光伏发电站功率预测系统技术要求》规范要求。

参考文献

[1] 龚莺飞，鲁宗相，乔颖，等．光伏功率预测技术[J]．电力系统自动化，2016，40(4)：140-152

[2] 张玉，张振涛，莫寒．光伏发电的预测综述[J]．制造业自动化，2015，37(11)：27-30．

[3] Heinrich Morf．The stochastic two-state cloud cover model STSCCM [J]．Solar Energy，2011 (85)：985-999．

[4] 王守相，张娜．基于灰色神经网络组合模型的光伏短期出力预测[J]．电力系统自动化，2012，36(19)：37-41．

[5] 姚仲敏，潘飞，沈玉会，等，基于 GA-BP和POS-BP神经网络的光伏电站出力短期预测[J]．电力系统保护与控制，2015，43(20)：83-89．

[6] 周志华．机器学习[M]．北京：清华大学出版社，2016．

[7] Peter harrington machine learing in action [M]．United States of America：Manning Publications，2012．

[8] 杨风暴，王肖霞．D-S证据理论的冲突合成方法[M]．北京：清华大学出版社，2010．

[9] 丛林虎，徐延学，荀凯．基于D-S证据理论的导弹制导控制系统的联合最小二乘支持向量机预测模型[J]．兵工学报，2015，36(8)：1466-1472．

[10] 陈毅波，郑玲，姚建刚．基于粗糙集理论与D-S证据理论改进的多元回归负荷预测方法[J]．电力系统保护与控制，2016，44(6)：62-67．

[11] 吴京秋，孙奇，杨伟，等．基于D-S证据理论的短期负荷预测模型融合[J]．电力自动化设备，2009，29(4)：66-70．

[12] 刘亚南，卫志龙，朱艳，等 基于D-S证据理论的短期风速预测模型[J]．电力自动化设备，2013，33(8)：131-136．

(收稿日期：2018－04－04)EA

(上接第90页)

策[J]．信息安全与通信保密，2014(6)：62-63．

[10] 王继业，孙利民，李晔，等．电力工控系统攻击仿真验证关键技术研究[J]．电力信息与通信技术，2017(6)：9-14．

[11] Baiardi F，Telmon C，Sgandurra D．Hierarchical，model-based risk management of critical infrastructures[J]．Reliability Engineering and System Safety，2009，94(9)：1403-1415．

[12] Esmalifalak M，Ge Shi，Zhu Han，et al．Bad data injection attack and defense in electricity market using game theory study[J]．IEEE Transactions on Smart Grid，2013，4(1)：160-169．

[13] Eom Jung-Ho，Han Young-Ju，Park Seon-Ho．Active cyber attack model for network system's vulnerability assessment[C]．2008 International Conference on Information Science and Security，Seoul，2008．

[14] 王德文，周青．一种电力设备状态监测大数据的分布式联机分析处理方法[J]．中国电机工程学报，2016(19)：5111-5121．

[15] 赵峰，乌大鹏．电力系统高速数据采集系统设计[J]．数字技术与应用，2013(3)：163．

[16] Jia Zhiwei，Wang Lijun，Zhang Jinchuan et al．High efficiency，low power-consumption DFB quantum cascade lasers without lateral regrowth[J]．Nanoscale Research Letters，2017，12(1):281．

(收稿日期：2018－08－14) EA