

DOI: 10.19783/j.cnki.pspc.201224

含风电和光伏的可再生能源场景削减方法

白斌¹, 韩明亮¹, 林江², 孙伟卿³

(1. 中国电建集团青海省电力设计院有限公司, 青海 西宁 810008; 2. 方自科技(上海)有限公司, 上海 201913;
3. 上海理工大学电气工程系, 上海 200093)

摘要: 以风电和光伏为代表的可再生能源渗透率不断增加, 其出力不确定性导致的大规模时序场景给电力系统的优化分析带来很高的计算复杂度。以场景削减技术精准刻画区域风电、光伏出力特性是解决以上问题的有效方法之一。提出一种基于聚类与优化算法相结合的可再生能源场景削减方法。首先对数据进行清洗、降噪等预处理, 其次利用肘部法则与轮廓系数判断风电、光伏类别个数并进行聚类。然后, 利用粒子群与遗传算法分别提取风电、光伏典型出力曲线, 并对两种算法结果进行对比, 从而生成典型场景。算例分析以欧洲输电系统运营商 Amprion 提供的 2015 年 1 月 1 日至 2019 年 12 月 31 日风电、光伏出力数据为研究对象, 利用所提方法求得的出力曲线可以有效反映该区域风电、光伏出力典型场景, 为后续电力系统规划、运行优化等问题提供数据支撑。

关键词: 场景削减; 扩展卡尔曼滤波; 聚类; 粒子群算法; 遗传算法

Scenario reduction method of renewable energy including wind power and photovoltaic

BAI Bin¹, HAN Mingliang¹, LIN Jiang², SUN Weiqing³

(1. Power China Qinghai Electric Power Engineering CO., LTD., Xining 810008, China; 2. Fangzi Technology (Shanghai) Co., Ltd., Shanghai 201913, China; 3. Department of Electrical Engineering, University of Shanghai for Science and Technology, Shanghai 200093, China)

Abstract: With the increasing penetration of renewable energy represented by wind power and photovoltaic, the large-scale time sequence scenario caused by the uncertainty of their output brings high computational complexity to the optimization analysis of a power system. One of the effective methods to solve the above problems is to accurately describe the regional wind power and photovoltaic output characteristics with scene reduction. In this paper, a scenario reduction method based on clustering and optimization algorithms is proposed. First, the data are preprocessed e.g. by cleaning and noise reduction. Secondly, the elbow method and silhouette coefficient are used to determine the number of wind power and photovoltaic categories and clusters. Then, the typical output curves of wind power and photovoltaic are extracted by particle swarm optimization and genetic algorithm respectively, and the results of the two algorithms are compared to generate typical scenarios. Taking the wind power and photovoltaic output data from January 1, 2015 to December 31, 2019 provided by European transmission system operator Amprion as the research object, the output curve obtained by the proposed method can effectively reflect the typical scenario of wind power and photovoltaic output in the region, and provide data support for subsequent power system planning and operation optimization.

This work is supported by the National Natural Science Foundation of China (No. 51777126).

Key words: scene reduction; extended Kalman filter; clustering; particle swarm optimization; genetic algorithm

0 引言

以风电和光伏为代表的可再生能源出力具有随机性、间歇性、波动性等特点^[1-2], 在未来高比例可

再生能源电力系统中, 其大规模并网将给电网的安全、稳定运行带来挑战^[3-4]。为了研究高比例可再生能源背景下电力系统规划、运行、调度等优化问题, 首先需要精准刻画风电、光伏出力的随机性与波动性特征, 并且解决大规模时序数据对优化程序所造成时间复杂度较高的问题, 因此需要对风电、光伏

基金项目: 国家自然科学基金项目资助(51777126)

出力场景进行削减以达到精简数据、减少计算量的目的^[5]。风电、光伏出力随着时间的变化呈现一定的季节或日周期性^[6]。因此,可以对风、光出力进行场景分析,将出力的不确定性转化为确定性场景,为后续电力系统规划、运行、调度等优化问题提供数据基础。

目前场景分析方法有三类:时序模拟法、典型日法与场景聚类法。时序模拟法如文献[7]采用蒙特卡洛法,考虑风电处理特性,模拟了全年的风电、负荷时序场景。典型日法将某一日的出力特性作为典型场景,文献[8]以全年负荷峰谷差最大的一天作为典型日用于含风电全年电力平衡计算,显然不能体现风电的出力特性。场景聚类法通过将具有一定相似度的曲线聚为一类,例如文献[9]采用 k -means 对全年风电、光伏、负荷数据进行聚类用于电力系统中长期规划。目前较为常用的是场景聚类法,因其结果能够准确体现场景特征,且计算效率较高。

大数据热潮将电网积累了多年的数据价值得以体现^[10]。聚类,即根据相似性原则,将具有较高相似度的数据划分至同一类簇,将具有较高相异度的数据对象划分至不同类簇,属于无监督学习,即待处理数据没有任何先验知识聚类作为一种机器学习算法,已经在电力系统中得到广泛应用,如场景削减^[6]、负荷聚类^[11-12]、异常识别^[13]等领域。常见的聚类算法有基于划分的聚类算法如 k -means、基于密度的聚类算法如 DBSCAN、基于层次聚类算法如 CURE 和其他聚类算法如谱聚类^[14]。

但是,目前文献缺少对于聚类结果如何提取典型特征的描述,重点过于强调聚类算法,因此本文提出一种基于聚类与优化算法相结合的可再生能源场景削减方法。首先对数据进行清洗、降噪等预处理,其次利用肘部法则(Elbow Method)与轮廓系数(Silhouette Coefficient)判断风电、光伏类别个数,并进行聚类。然后,利用粒子群与遗传算法提取典型出力曲线,对两种算法结果进行对比,从而生成典型场景。算例分析以欧洲输电系统运营商 Amprion 提供的 2015 年 1 月 1 日至 2019 年 12 月 31 日风、光数据作为研究对象。

1 风、光场景削减总体框架

基于聚类与优化算法相结合的可再生能源场景削减方法框架如图 1 所示,分为四个步骤:

1) 将数据中缺失值、异常值进行剔除,保留完整每日时序数据。利用扩展卡尔曼滤波对数据进行降噪后进行标准化处理,完成数据预处理。

2) 对风电、光伏数据分别按年度与月度进行统

计分析以发现规律。

3) 利用 Elbow Method 与 Silhouette Coefficient 综合选择 k 值,然后分别对风电、光伏数据根据各自 k 值利用 k -means 进行聚类。

4) 对聚类结果曲线分别利用遗传算法与粒子群算法提取典型出力曲线,将结果进行对比,选择适合的优化算法所对应的典型场景。

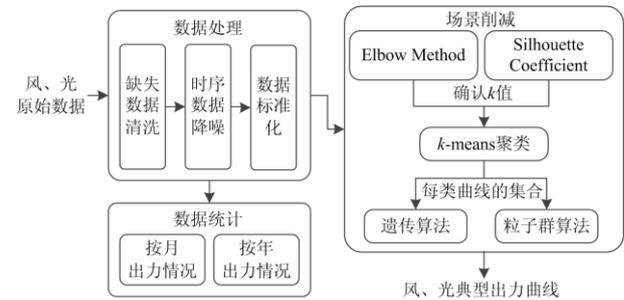


图 1 场景削减框架

Fig. 1 Framework of scenario reduction

2 数据预处理

2.1 缺失数据清洗

数据的准确性是聚类分析的前提。一般可处理的数据问题分为三种:人类认知范围内明显异常的数据;对于电脑来说不符合一贯数据规律的离群点;由底层硬件和传输过程不稳定所导致的数据偏差。

由于数据来源多样,且传感器在采集过程中容易产生数据丢失、延迟传输等现象^[15]。因此剔除一天内连续缺失数据较多的日期,而对于一天内缺失数据较小的情况,采用平均插值法进行填充。

2.2 时序数据降噪

由于数据采集及传输过程中的不稳定,因此采用扩展卡尔曼滤波算法(Extended Kalman Filter, EKF)对数据进行降噪处理^[16-17],一定意义上提高数据的精度。

电力系统为时变非线性系统,对于稳态运行的电力系统,可视为离散时变非线性系统,对其建立模型如式(1)所示。

$$x_{k+1} = F_k x_k + G_k \quad (1)$$

式中: x_k 为 k 时刻的风、光出力; F_k 为状态转移矩阵; G_k 为时变系统噪声。

EKF 滤波过程包括状态预测和状态滤波两步。状态预测如式(2)所示。

$$\begin{cases} \bar{x}_{k+1} = F_k \hat{x}_k + G_k \\ \bar{P}_{k+1} = F_k P_k F_k^T + Q_k \end{cases} \quad (2)$$

式中: \bar{P}_{k+1} 、 P_k 分别为 $k+1$ 与 k 时刻状态向量预测值和估计值误差协方差矩阵; Q_k 为模型噪声向量协

方差矩阵, 其对角元素取常数 q , 该矩阵反映相邻时刻系统状态变化程度, 一般根据先验信息选取。

状态预测后, 对状态向量预测值进行一步修正, 状态滤波如式(3)所示。

$$\begin{cases} \hat{x}_{k+1} = \bar{x}_{k+1} + \mathbf{K}_{k+1}[z_{k+1} - h(\bar{x}_{k+1})] \\ \mathbf{K}_{k+1} = \bar{\mathbf{P}}_{k+1} \mathbf{H}_{k+1}^T [\mathbf{H}_{k+1} \bar{\mathbf{P}}_{k+1} \mathbf{H}_{k+1}^T + \mathbf{R}_{k+1}]^{-1} \\ \bar{\mathbf{P}}_{k+1} = [\mathbf{I} - \mathbf{K}_{k+1} \mathbf{H}_{k+1}] \bar{\mathbf{P}}_{k+1} \end{cases} \quad (3)$$

式中: z_{k+1} 为 $k+1$ 时刻量测值; \mathbf{R}_{k+1} 为 $k+1$ 时刻量测误差协方差矩阵; \mathbf{H}_{k+1} 为 $k+1$ 时刻量测量对状态量的雅可比矩阵; \mathbf{K}_{k+1} 为 $k+1$ 时刻的卡尔曼增益矩阵。

2.3 数据标准化

采用 Z-Score 对每类连续型数据进行处理。

$$X^* = \frac{X - \mu}{\sigma} \quad (4)$$

式中: X^* 为标准化后的日风、光出力值; X 为原始日风、光出力值; μ 为日风、光出力的均值; σ 为日风、光出力的方差。

3 风、光场景聚类

风、光发电受到自然天气条件因素影响, 发电量变化趋势明显^[18]。本文利用 k -means 算法进行聚类, 针对风、光出力等时序数据, k -means 作为基于欧式距离的聚类方法能够更好地聚合形状相似、大小相近的曲线^[19]。此外, k -means 的缺点是容易受到噪声的影响, 而风、光出力曲线已经过 EKF 滤波。因此本文采用简单、高效的 k -means 算法。

k -means 聚类算法是一种基于划分的聚类算法, 以距离作为数据间相似性度量的标准, k 代表类簇个数。而聚类分析中聚类个数 k 的确定对聚类质量至关重要^[20]。本文利用 Elbow Method 与 Silhouette Coefficient 综合判定 k 值。

k -means 是以最小化样本与质点平方误差作为目标函数, 将每个簇的质点与簇内样本点的平方距离误差和(within-cluster sum of squared errors, SSE)称为畸变程度。对于一个簇, 畸变程度越低, 代表簇内成员越紧密, 畸变程度越高, 代表簇内结构越松散。畸变程度会随着类别的增加而降低, 但对于有一定区分度的数据, 在达到某个临界点时畸变程度会得到极大改善, 之后缓慢下降, 这个临界点就可以考虑为聚类性能较好的点, 即 Elbow Method^[21]。

Silhouette Coefficient 是类的密集与分散程度的评价指标^[22], 如式(5)所示。

$$s = b - a \cdot \max(a, b) \quad (5)$$

式中: a 为同簇样本与彼此之间距离的均值; b 为样本与除自身所在簇外的最近簇内样本距离的均值; s

为 Silhouette Coefficient, 取值为 $[-1, 1]$, 越接近 1 代表 k 值越合理。

4 风、光典型日曲线优化模型建立与求解

风、光分别聚类后得到 k_{wind} 、 k_{pv} 类出力场景。其中: 风电第 i 类出力场景 P_i^{wind} 共有 j 条日出力曲线; 光伏第 x 类出力场景 P_x^{pv} 共有 y 条日出力曲线。如式(6)与式(7)所示。

$$P_i^{\text{wind}} = [P_1^{\text{wind},i}, P_2^{\text{wind},i}, \dots, P_j^{\text{wind},i}] = \begin{bmatrix} [p_{0_1}^{\text{wind},i}, p_{1_1}^{\text{wind},i}, \dots, p_{23_1}^{\text{wind},i}] \\ \vdots \\ [p_{0_j}^{\text{wind},i}, p_{1_j}^{\text{wind},i}, \dots, p_{23_j}^{\text{wind},i}] \end{bmatrix}, i \in k_{\text{wind}} \quad (6)$$

$$P_x^{\text{pv}} = [P_1^{\text{pv},x}, P_2^{\text{pv},x}, \dots, P_y^{\text{pv},x}] = \begin{bmatrix} [p_{0_1}^{\text{pv},x}, p_{1_1}^{\text{pv},x}, \dots, p_{23_1}^{\text{pv},x}] \\ \vdots \\ [p_{0_y}^{\text{pv},x}, p_{1_y}^{\text{pv},x}, \dots, p_{23_y}^{\text{pv},x}] \end{bmatrix}, x \in k_{\text{pv}} \quad (7)$$

式中: $P_j^{\text{wind},i}$ 与 $P_y^{\text{pv},x}$ 表示风、光第 i 类与第 x 类中第 j 条与第 y 条日出力曲线, 其中包含 24 个功率点。

提取典型曲线可以基于距离或者基于相关性系数。基于距离的方法可能会因为簇内离群点影响造成误差较大, 因此本文采用基于皮尔逊相关系数的提取日典型曲线方法, 使得所求日典型曲线与簇内所有日曲线的相关性系数之和最大, 风、光目标函数分别对应式(8)与式(11)。

$$\max_{P_i^{\text{wind},i}} \sum_{l=1}^j \rho_{l,i}^{\text{wind}} = \sum_{l=1}^j \frac{\text{cov}(P_l^{\text{wind},i}, P_i^{\text{wind},i})}{\sigma_{P_l^{\text{wind},i}} \sigma_{P_i^{\text{wind},i}}} = \sum_{l=1}^j \frac{E((P_l^{\text{wind},i} - \mu_{P_l^{\text{wind},i}})(P_i^{\text{wind},i} - \mu_{P_i^{\text{wind},i}}))}{\sigma_{P_l^{\text{wind},i}} \sigma_{P_i^{\text{wind},i}}} \quad (8)$$

$$\text{s.t.} \quad \min \{p_m^{\text{wind},i}\} \leq p_l^{\text{wind},i} \leq \max \{p_m^{\text{wind},i}\} \quad (9)$$

$$1 \leq m \leq j \quad (10)$$

$$\max_{P_x^{\text{pv},x}} \sum_{l=1}^y \rho_{l,x}^{\text{pv}} = \sum_{l=1}^y \frac{\text{cov}(P_l^{\text{pv},x}, P_x^{\text{pv},x})}{\sigma_{P_l^{\text{pv},x}} \sigma_{P_x^{\text{pv},x}}} = \sum_{l=1}^y \frac{E((P_l^{\text{pv},x} - \mu_{P_l^{\text{pv},x}})(P_x^{\text{pv},x} - \mu_{P_x^{\text{pv},x}}))}{\sigma_{P_l^{\text{pv},x}} \sigma_{P_x^{\text{pv},x}}} \quad (11)$$

$$\text{s.t.} \quad \min \{p_n^{\text{pv},x}\} \leq p_l^{\text{pv},x} \leq \max \{p_n^{\text{pv},x}\} \quad (12)$$

$$1 \leq n \leq y \quad (13)$$

式中: $\rho_{l,i}^{\text{wind}}$ 与 $\rho_{l,x}^{\text{pv}}$ 为第 i 类与第 x 类内第 l 条日出力曲线与日典型风、光出力曲线的皮尔逊相关性系数; $P_l^{\text{wind},i}$ 与 $P_l^{\text{pv},x}$ 为第 i 类与第 x 类日典型风、光日出力曲线, 其中包含 24 个功率点。对于优化模型,

本文同时采取粒子群算法(Particle Swarm Optimization, PSO)与遗传算法(Genetic Algorithm, GA)进行求解,对比两种算法在不同场景下的表现。

5 算例分析

实验计算基于 Python3.7 运行环境,利用欧洲输电系统运营商 Amprion 提供的 2015 年 1 月 1 日至 2019 年 12 月 31 日风、光数据作为研究对象,采集的颗粒度为 15 min。

5.1 数据处理及统计

首先对原始数据进行清洗及降噪。剔除数据中的异常值并保留完整每日时序数据,然后利用 EKF 算法进行降噪,降噪前后对比如图 2 所示。降噪后,风、光出力曲线更加平滑,且极大地保留了其特征。

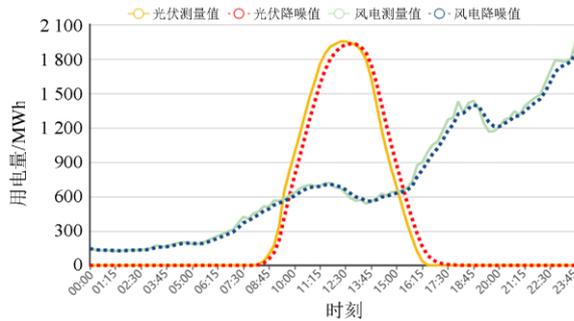


图 2 风、光出力数据降噪前后对比

Fig. 2 Comparison of wind and photovoltaic power output data before and after noise reduction

对处理后的风电、光伏数据分别按年度与月度进行统计分析以发现风电在每年 1 月、2 月、3 月、7 月、11 月、12 月出力较高,且最高均可在 15 min 内出力达 8 000 MW 以上。风电在 5 月、6 月、8 月相对较低,基本每 15 min 出力集中在 4 000 MW 以内。风电曲线基本平缓,一天内几乎没有明显的浮动,且在冬季出力较高。

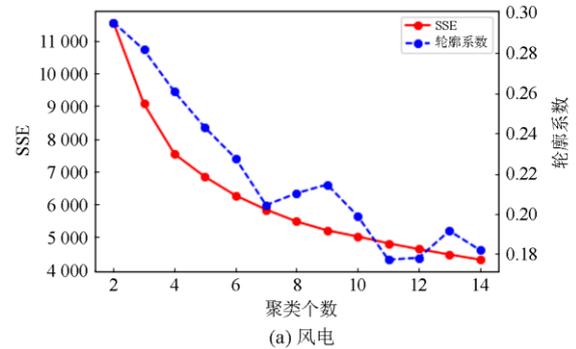
光伏在每年 4 月至 7 月期间出力较高,最高出力每 15 min 均可达 7 000 MW。而 1 月、11 月、12 月出力较低。光伏出力曲线存在明显特征,受光照影响,正午出力最高,夜间出力为零。因此,在夏季出力较高。风电和光伏在月份层面呈互补趋势。

5.2 风、光场景聚类

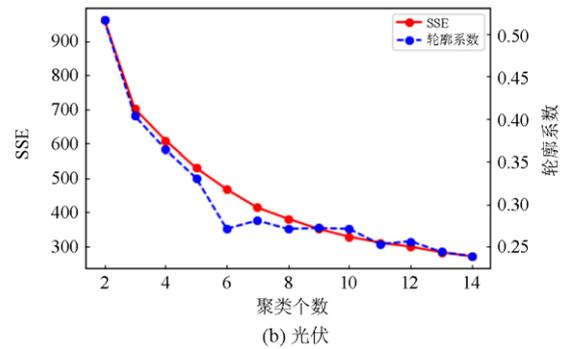
首先,根据 Elbow Method 与 Silhouette Coefficient 综合判定 k 值,如图 3 所示。

图中,左 y 轴 SSE 为 Elbow Method 所得结果,而右半轴为 Silhouette Coefficient 所得结果。首先由 Elbow Method 可知,风电聚类个数可选择范围在 5~8 之间,光伏聚类个数在 4~8 之间。而根据

Silhouette Coefficient 尽量大的原则,选择风电聚类个数 k 为 6,光伏聚类个数 k 为 5。



(a) 风电

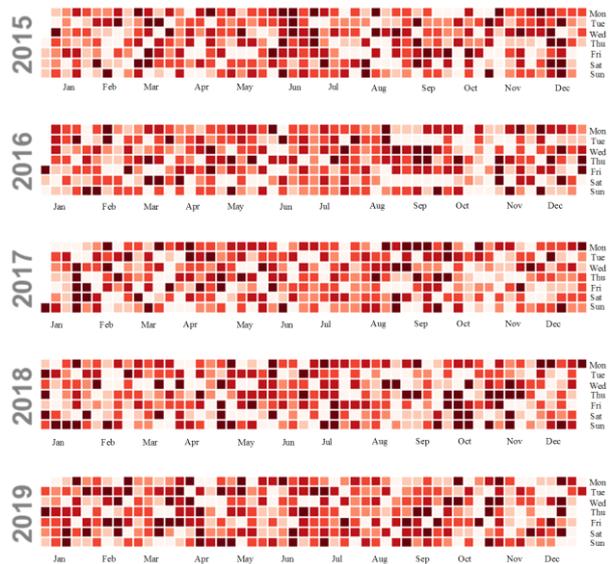


(b) 光伏

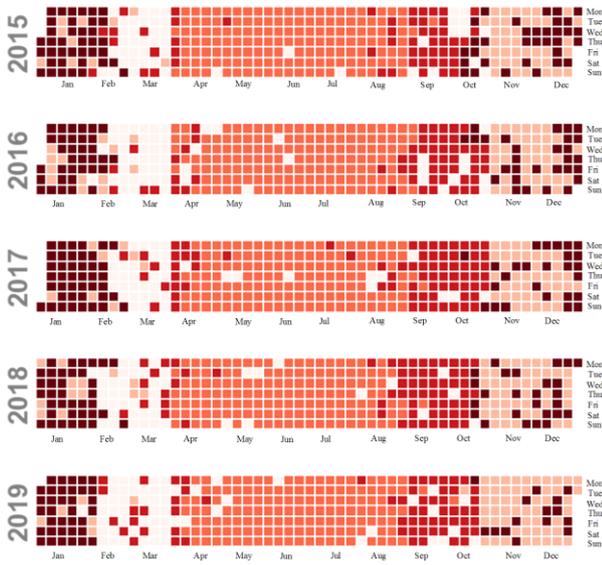
图 3 风、光聚类个数的确定

Fig. 3 Determination of the number of wind and photovoltaic power clusters

聚类结果标签如图 4 所示。发现风电聚类结果在时间上较为分散,没有明显规律。而光伏聚类结果与季节相关,在月份上呈明显的划分趋势,一般而言,1 月为一类、2 月至 3 月为一类、4 月至 8 月为一类、9 月至 10 月为一类、11 月至 12 月为一类,因此聚类结果可能与光照强度有关。



(a) 风电聚类标签

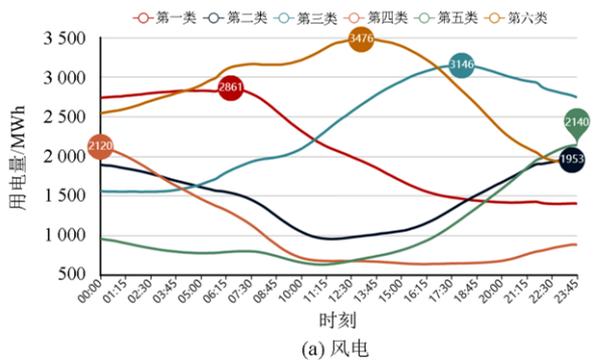


(b) 光伏聚类标签

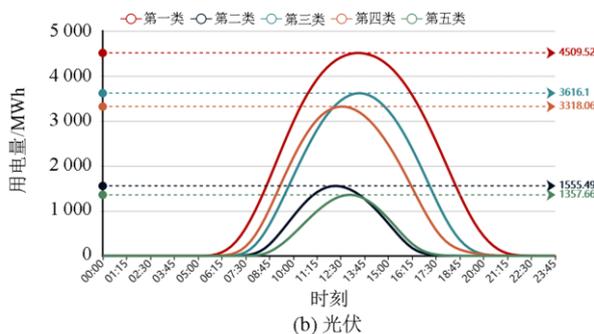
图 4 聚类标签

Fig. 4 Cluster label

然后, 根据聚类结果对每类出力曲线简单求取平均值, 以便发现规律, 如图 5 所示。



(a) 风电



(b) 光伏

图 5 风、光各类场景平均曲线

Fig. 5 Average curve of wind and photovoltaic power scenes

可见风电各个场景平均曲线形状差异较大, 峰谷可以出现在一天中的任意时段内。而光伏各个场景平均曲线形状几乎没有差异, 峰值集中在 12 点至 14 点间, 并且平均出力较大的曲线集中在夏季。因

为德国在北半球, 夏季一般日出较早、日落较晚, 冬季则反之, 说明聚类结果符合自然规律。

5.3 风、光典型日曲线提取

本文同时采取 PSO^[23]与 GA 对第 4 节所提出的优化模型进行求解。针对风电典型日曲线提取, 关键参数如表 1 所示, 优化结果如图 6 所示。

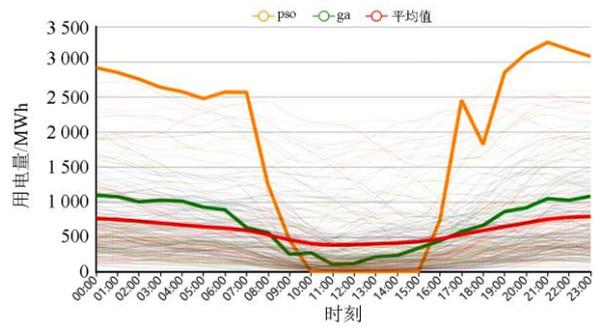
表 1 风电典型日曲线提取优化模型关键参数

Table 1 Key parameters of optimal model for extracting typical daily wind power curve

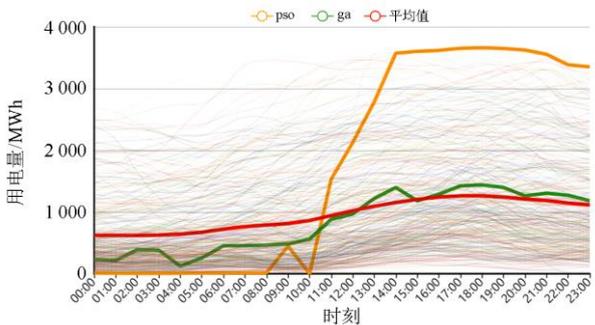
算法	参数名	参数值
PSO	惯性权重 ω	0.8
	学习因子 c_1	2
	学习因子 c_2	2
GA	种群个数	100
	精度	1e-5
	种群个数	130



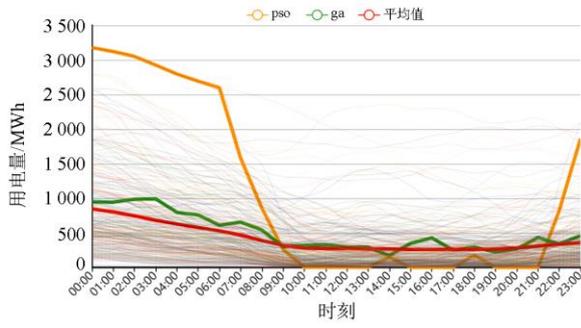
(a) 风电第一类典型场景



(b) 风电第二类典型场景



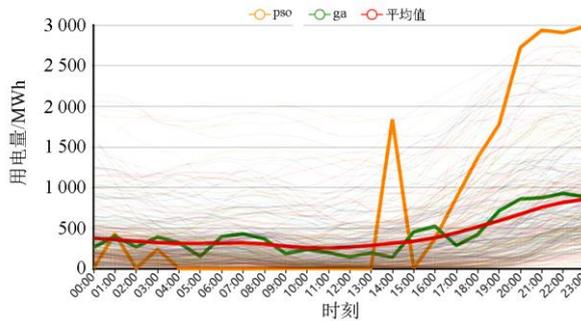
(c) 风电第三类典型场景



(d) 风电第四类典型场景



(f) 风电第六类典型场景



(e) 风电第五类典型场景

图 6 风电典型场景下优化算法比较

Fig. 6 Comparison of optimization algorithms in typical wind power scenarios

发现在风电场景下，GA 算法效果优于 PSO 算法。虽然对 PSO 参数不断调整，但其优化结果极差。GA 算法结果更加贴近平均值，然而简单的平均曲线难以表征场景特性。因此在风电场景下，采用 GA 算法所得结果。风电典型日曲线数据如表 2 所示。

针对光伏典型日曲线提取，关键参数如表 3 所示，优化结果如图 7 所示。

表 2 风电典型日曲线

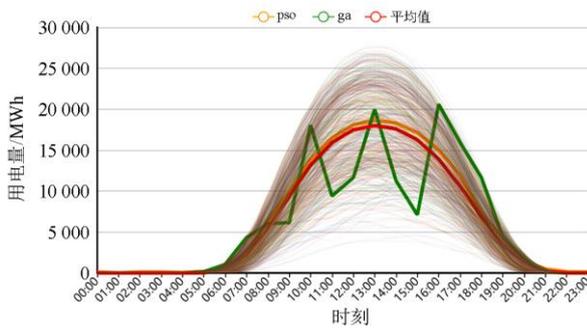
Table 2 Typical daily curve of wind power

	MWh					
时段	场景一	场景二	场景三	场景四	场景五	场景六
00:00—01:00	13 604.81	10 913.07	2 342.70	9 475.83	2 639.51	6 089.23
01:00—02:00	13 823.73	10 738.79	2 133.47	9 425.87	3 995.40	9 102.63
02:00—03:00	13 839.75	10 002.88	3 906.48	9 852.93	2 689.21	8 525.05
03:00—04:00	14 489.18	10 236.84	3 815.30	9 914.83	3 916.15	9 995.35
04:00—05:00	14 848.91	10 111.24	1 209.66	7 959.60	3 221.52	10 605.91
05:00—06:00	13 680.92	9 241.03	2 565.51	7 556.41	1 519.96	10 759.70
06:00—07:00	12 744.72	8 852.82	4 521.90	6 096.25	3 956.25	12 656.82
07:00—08:00	14 459.31	6 325.84	4 559.25	6 551.61	4 301.45	12 044.78
08:00—09:00	13 745.02	5 597.19	4 650.51	5 409.44	3 690.61	10 518.66
9:00—10:00	12 441.49	2 510.16	4 825.17	3 009.73	1 871.84	11 179.36
10:00—11:00	8 212.08	2 715.14	5 599.95	3 191.13	2 377.96	11 284.32
11:00—12:00	9 788.65	1 074.01	8 807.87	3 267.28	1 992.95	14 984.40
12:00—13:00	7 358.34	1 193.07	9 682.22	2 942.14	1 445.52	11 818.20
13:00—14:00	5 964.55	2 133.05	12 183.92	2 928.02	1 968.27	12 871.35
14:00—15:00	5 188.16	2 348.21	13 966.58	1 694.85	1 410.50	14 037.98
15:00—16:00	6 399.90	3 385.65	11 793.61	3 482.51	4 530.76	13 193.45
16:00—17:00	6 514.71	4 423.96	12 863.86	4 256.98	5 242.41	12 405.36
17:00—18:00	5 360.96	5 767.61	14 226.66	2 511.10	2 865.46	12 843.30
18:00—19:00	4 049.60	6 635.03	14 374.27	2 947.15	4 226.21	7 694.62
19:00—20:00	3 571.53	8 599.36	13 974.17	2 200.20	7 126.20	6 410.92
20:00—21:00	5 326.17	9 147.04	12 603.17	2 675.29	8 582.80	2 300.39
21:00—22:00	4 447.35	10 454.90	13 052.25	4 321.71	8 744.08	3 359.16
22:00—23:00	5 867.18	10 210.58	12 689.47	3 382.30	9 284.78	3 135.06
23:00—00:00	3 891.47	10 797.71	11 836.08	4 580.74	8 866.55	2 677.78

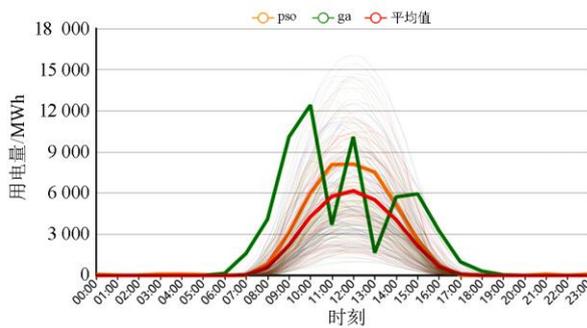
表 3 光伏典型日曲线提取优化模型关键参数

Table 3 Key parameters of optimal model for extracting typical daily photovoltaic power curve

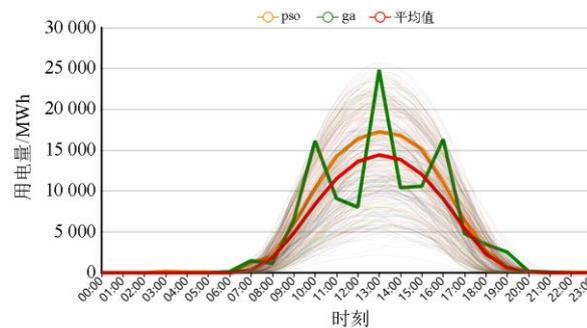
算法	参数名	参数值
PSO	惯性权重 ω	0.8
	学习因子 c_1	2
	学习因子 c_2	2
	种群个数	100
GA	精度	1e-2
	种群个数	50



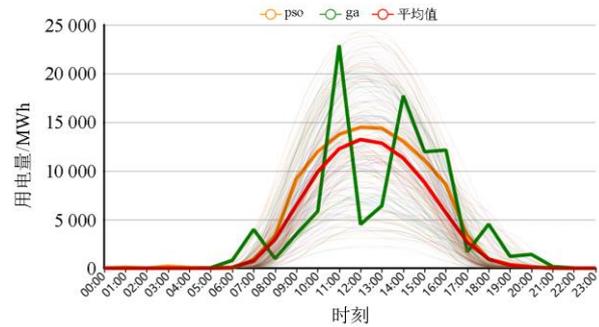
(a) 光伏第一类典型场景



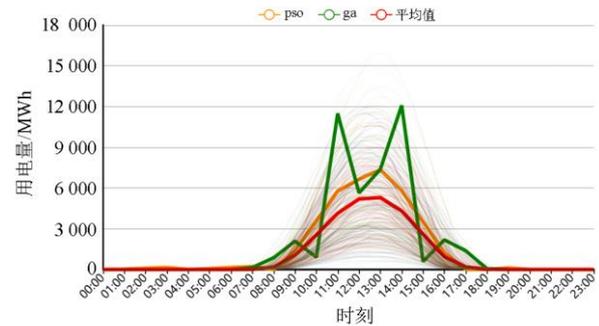
(b) 光伏第二类典型场景



(c) 光伏第三类典型场景



(d) 光伏第四类典型场景



(e) 光伏第五类典型场景

图 7 光伏典型场景下优化算法比较

Fig. 7 Comparison of optimization algorithms in typical photovoltaic scenarios

发现在光伏场景下,基本 PSO 算法效果优于 GA 算法。GA 算法在均出现了一定的畸变,推测可能是在光伏场景下 GA 更易陷入局部最优点所导致。因此在光伏场景下,均采用 PSO 算法所得结果。光伏典型日曲线数据如表 4 所示。

6 结论

本文提出一种基于聚类与优化算法相结合的可再生能源场景削减方法,得出以下结论:

1) 利用 Elbow Method 与 Silhouette Coefficient 两种衡量指标共同确定聚类 k 值,更加准确有效。

2) 采用皮尔逊相关系数衡量曲线之间的相似性并建立优化模型,可以有效地提取风电、光伏典型出力曲线。

3) 在风电与光伏不同场景下,适用不同的优化算法。针对风电场景,GA 算法效果较好,但 PSO 即便不断调试参数,结果依然陷入局部最优。针对光伏场景,PSO 算法效果更好,GA 会在局部点产生畸变,可能是由于陷入局部最优所导致的。

本文所提取的 5 种光伏典型场景与 6 种风电典型场景将为后续电力系统规划、运行、调度等优化问题提供数据基础。

表 4 光伏典型日曲线
Table 4 Typical daily curve of photovoltaic power

MWh					
时段	场景一	场景二	场景三	场景四	场景五
00:00—01:00	0.00	0.00	0.00	0.00	0.00
01:00—02:00	0.00	0.00	0.00	0.00	0.00
02:00—03:00	0.00	0.00	0.00	0.00	0.00
03:00—04:00	0.00	0.00	0.00	0.00	0.00
04:00—05:00	0.00	0.00	0.00	0.00	0.00
05:00—06:00	0.00	0.00	0.00	0.00	0.00
06:00—07:00	693.33	0.00	0.00	0.00	0.00
07:00—08:00	2 505.87	0.00	1 218.67	876.70	0.00
08:00—09:00	6 534.00	832.20	2 034.75	3 352.58	0.00
09:00—10:00	9 938.47	3 117.84	5 976.93	9 170.00	1 419.10
10:00—11:00	13 898.00	5 993.57	10 319.77	11 978.24	3 594.34
11:00—12:00	16 514.00	8 083.93	14 230.00	13 735.88	5 773.18
12:00—13:00	18 087.33	8 111.00	16 378.67	14 472.94	6 652.73
13:00—14:00	18 656.00	7 536.05	17 225.33	14 370.59	7 345.00
14:00—15:00	18 322.00	5 155.34	16 796.00	13 046.47	5 811.63
15:00—16:00	17 131.33	2 604.97	15 148.67	11 068.24	3 531.94
16:00—17:00	15 013.33	747.16	11 136.72	8 582.94	1 207.07
17:00—18:00	11 972.67	0.00	6 414.98	3 328.09	0.00
18:00—19:00	7 402.61	0.00	2 718.77	928.21	0.00
19:00—20:00	4 412.67	0.00	690.39	390.07	0.00
20:00—21:00	1 467.44	0.00	0.00	153.07	0.00
21:00—22:00	490.67	0.00	0.00	0.00	0.00
22:00—23:00	0.00	0.00	0.00	0.00	0.00
23:00—00:00	0.00	0.00	0.00	0.00	0.00

参考文献

- [1] HUANG Hao, LI Fangxing, YATEENDRA M. Modeling dynamic demand response using Monte Carlo simulation and interval mathematics for boundary estimation[J]. IEEE Transactions on Smart Grid, 2015, 6(6): 2704-2713.
- [2] 杨欢红, 王洁, 邵能灵, 等. 基于灰靶决策和多目标布谷鸟算法的微电网分布式电源鲁棒优化[J]. 电力系统保护与控制, 2019, 47(1): 20-27.
- YANG Huanhong, WANG Jie, TAI Nengling, et al. Robust optimization of distributed generation in a microgrid based on grey target decision-making and multi-objective cuckoo search algorithm[J]. Power System Protection and Control, 2019, 47(1): 20-27.
- [3] 孙毅, 李泽坤, 许鹏, 等. 异构柔性负荷建模调控关键技术及发展方向研究[J]. 中国电机工程学报, 2019, 39(24): 7146-7158.
- SUN Yi, LI Zekun, XU Peng, et al. Research on key technologies and development direction of heterogeneous flexible load modeling and regulation[J]. Proceedings of the CSEE, 2019, 39(24): 7146-7158.
- [4] 孙伟卿, 裴亮, 向威, 等. 电力系统中储能的系统价值评估方法[J]. 电力系统自动化, 2019, 43(8): 47-55.
- SUN Weiqing, PEI Liang, XIANG Wei, et al. Evaluation method of system value for energy storage in power system[J]. Automation of Electric Power Systems, 2019, 43(8): 47-55.
- [5] 黄冯. 面向电力系统分析的可再生能源典型场景生成方法[D]. 合肥: 合肥工业大学, 2019.
- HUANG Feng. A typical scenario generation method for renewable energy in power system analysis[D]. Hefei: Hefei University of Technology, 2019.
- [6] 林俐, 肖舒, 费宏运, 等. 基于曲线形态特征的地区规模化风电出力场景划分[J]. 电网与清洁能源, 2020, 36(3): 74-81, 88.
- LIN Li, XIAO Shu, FEI Hongyun, et al. Regional scaled wind power output scene segmentation based on curve morphological features[J]. Power System and Clean Energy, 2020, 36(3): 74-81, 88.
- [7] 刘挺坚, 刘友波, 刘若凡. 风电外送断面极限输电能力的非参数回归估计[J]. 电网技术, 2017, 41(11): 3514-3522.
- LIU Tingjian, LIU Youbo, LIU Ruofan. Nonparametric regression estimation for total transfer capability of transmission interface considering centralized wind power integration[J]. Power System Technology, 2017, 41(11): 3514-3522.

- [8] 刘纯, 曹阳, 黄越辉, 等. 基于时序仿真的风电年度计划制定方法[J]. 电力系统自动化, 2014, 38(11): 13-19.
LIU Chun, CAO Yang, HUANG Yuehui, et al. An annual wind power planning method based on time sequential simulations[J]. Automation of Electric Power Systems, 2014, 38(11): 13-19.
- [9] 丁明, 解蛟龙, 刘新宇, 等. 面向风电接纳能力评价的风资源/负荷典型场景集生成方法与应用[J]. 中国电机工程学报, 2016, 36(15): 4064-4072.
DING Ming, XIE Jiaolong, LIU Xinyu, et al. The generation method and application of wind resources/load typical scenario set for evaluation of wind power grid integration[J]. Proceedings of the CSEE, 2016, 36(15): 4064-4072.
- [10] 张东霞, 苗新, 刘丽平, 等. 智能电网大数据技术发展研究[J]. 中国电机工程学报, 2015, 35(1): 2-12.
ZHANG Dongxia, MIAO Xin, LIU Liping, et al. Research on development strategy for smart grid big data[J]. Proceedings of the CSEE, 2015, 35(1): 2-12.
- [11] 刘季昂, 刘友波, 程明畅, 等. 基于分位数半径动态 K-means 的分布式负荷聚类算法[J]. 电力系统保护与控制, 2019, 47(24): 15-22.
LIU Ji'ang, LIU Youbo, CHENG Mingchang, et al. A distributed load clustering algorithm based on quantile radius dynamic K-means[J]. Power System Protection and Control, 2019, 47(24): 15-22.
- [12] 吴亚雄, 高崇, 曹华珍, 等. 基于灰狼优化聚类算法的日负荷曲线聚类分析[J]. 电力系统保护与控制, 2020, 48(6): 68-76.
WU Yaxiong, GAO Chong, CAO Huazhen, et al. Clustering analysis of daily load curves based on GWO algorithm[J]. Power System Protection and Control, 2020, 48(6): 68-76.
- [13] 刘建锋, 张科翌, 高亮, 等. 基于继电保护信息与改进谱聚类分析的电网故障区域识别算法[J]. 电力系统保护与控制, 2019, 47(14): 37-43.
LIU Jianfeng, ZHANG Kezhao, GAO Liang, et al. Power grid fault region identification algorithm based on relay protection information and improved spectral clustering analysis[J]. Power System Protection and Control, 2019, 47(14): 37-43.
- [14] 章永来, 周耀鉴. 聚类算法综述[J]. 计算机应用, 2019, 39(7): 1869-1882.
ZHANG Yonglai, ZHOU Yaojian. Review of clustering algorithms[J]. Journal of Computer Applications, 2019, 39(7): 1869-1882.
- [15] 王文华, 王田, 吴群, 等. 传感网中时延受限的移动式数据收集方法综述[J]. 计算机研究与发展, 2017, 54(03): 474-492.
WANG Wenhua, WANG Tian, WU Qun, et al. Survey of delay-constrained data collection with mobile elements in WSNs[J]. Journal of Computer Research and Development, 2017, 54(3): 474-492.
- [16] 潘迪夫, 刘辉, 李燕飞. 基于时间序列分析和卡尔曼滤波算法的风电场风速预测优化模型[J]. 电网技术, 2008, 32(7): 82-86.
PAN Difu, LIU Hui, LI Yanfei. A wind speed forecasting optimization model for wind farms based on time series analysis and Kalman filter algorithm[J]. Power System Technology, 2008, 32(7): 82-86.
- [17] 李江, 王义伟, 魏超, 等. 卡尔曼滤波理论在电力系统中的应用综述[J]. 电力系统保护与控制, 2014, 42(6): 135-144.
LI Jiang, WANG Yiwei, WEI Chao, et al. A survey on the application of Kalman filtering method in power system[J]. Power System Protection and Control, 2014, 42(6): 135-144.
- [18] 蓝澜. 新能源发电特性与经济性分析研究[D]. 北京: 华北电力大学, 2014.
LAN Lan. Research on characteristics and economy of new energy power generation[D]. Beijing: North China Electric Power University, 2014.
- [19] 王千, 王成, 冯振元, 等. K-means 聚类算法研究综述[J]. 电子设计工程, 2012, 20(7): 21-24.
WANG Qian, WANG Cheng, FENG Zhenyuan, et al. Review of K-means clustering algorithm[J]. Electronic Design Engineering, 2012, 20(7): 21-24.
- [20] ZHOU Shibing, XU Zhenyuan, LIU Fei. Method for determining the optimal number of clusters based on agglomerative hierarchical clustering[J]. IEEE Transactions on Neural Networks and Learning Systems, 2017, 28(12): 3007-3017.
- [21] JEON J Y, CHOI J S, BYUN H G. Implementation of elbow method to improve the gases classification performance based on the RBFN-NSG algorithm[J]. Journal of Sensor Science and Technology, 2016, 25(6): 431-434.
- [22] ZHOU Hongbo, GAO Juntao. Automatic method for determining cluster number based on silhouette coefficient[J]. Advanced Materials Research, 2014, 3244: 227-230.
- [23] 黄河, 朱磊, 高松, 等. 提升分布式电源消纳的配网快速遍历重构方法[J]. 电力科学与技术学报, 2019, 34(3): 166-172.
HUANG He, ZHU Lei, GAO Song, et al. Reconfiguration method of distribution system for increasing the penetration of distributed generation[J]. Journal of Electric Power Science and Technology, 2019, 34(3): 166-172.

收稿日期: 2020-10-12; 修回日期: 2020-12-08

作者简介:

白斌(1984—), 男, 高级工程师, 主要从事电力工程方面的工作;

韩明亮(1995—), 男, 助理工程师, 主要从事新能源光伏本体及电气一次设计工作;

林江(1980—), 男, 高级工程师, 主要从事电力系统科技合作与成果推广应用工作。

(编辑 张爱琴)