

# 基于改进KDE法和GA-SVM的多风电场聚合后 输出功率长期波动特性预测方法

肖白<sup>1</sup>, 邢世亨<sup>2</sup>, 王茂春<sup>3</sup>, 杨森林<sup>3</sup>, 苟晓侃<sup>3</sup>

(1. 东北电力大学 电气工程学院, 吉林 吉林 132012;

2. 国网吉林省电力有限公司延边供电公司, 吉林 延吉 133000; 3. 国网青海省电力公司, 青海 西宁 810008)

**摘要:**针对规划期内有新增风电装机容量但没有与其对应的实测风电输出功率数据, 导致难以准确把握和刻画规划目标年多风电场聚合后输出功率长期波动特性的问题, 提出一种利用改进核密度估计(KDE)法和遗传算法寻优的支持向量机(GA-SVM)预测多风电场聚合后输出功率长期波动特性的方法。对风电功率的长期波动特性进行刻画, 分析在多风电场聚合过程中装机容量与风电功率之间的关系; 运用改进KDE法生成多风电场聚合过程中不同装机容量下的输出功率概率密度曲线; 采用GA-SVM建立多风电场聚合后输出功率概率密度演变模型; 根据概率分布与持续功率曲线的对应关系, 对预测出的规划目标年的多风电场聚合后的输出功率概率密度曲线进行反演, 得到可描述规划目标年输出功率长期波动特性的持续功率曲线。工程实例证明了所提方法的实用性和有效性。

**关键词:**多风电场; 风电波动特性; 核密度估计; 支持向量机

**中图分类号:**TM 714; TM 614

**文献标志码:**A

**DOI:**10.16081/j.epae.202111015

## 0 引言

为应对传统化石资源枯竭和环境污染等问题, 我国大力开发利用风能资源。然而风的随机性和不确定性使得大规模风电并网给电力系统规划与运行带来不利影响<sup>[1]</sup>。正确分析、把握和利用风电功率波动特性是实现含风电电力系统优化规划、调度和控制的基础<sup>[2-4]</sup>。

风电功率波动特性就是对风电输出功率波动在单位时间内变化情况的描述与刻画。对不同时段内风电功率波动特性的研究对应于处理含风电电力系统中不同方面的问题。考虑到电力系统规划工作通常是以年为单位的, 需要把握未来某年内的风电功率波动特性, 而电力系统日前调度和实时控制工作通常是以天和分钟为单位的, 需要把握未来一天或几分钟内的风电功率波动特性, 因此本文将前者称为长期波动特性, 将后者称为短期波动特性。

未来的风电功率波动特性是未知的, 通常需采取预测手段。预测过程中涉及采样时间尺度的问题, 即数据的采样间隔选取问题, 目前常用的采样间隔为5 min、15 min、1 h和1 a。由于风电功率波动特性分析的单位时间不同于风电功率预测中的采样时间尺度和预测周期, 但它们之间又有匹配关系, 因此研究规划目标年的风电功率长期波动特性不但具有重要的理论意义, 而且对于解决大规模风电并网导

致的电力系统规划难题具有重大的工程实用价值。

目前针对风电功率长期波动特性的研究较少。文献[5]提出一种基于利用持续功率曲线刻画风电功率长期波动特性的风电场群功率汇聚外送输电容量的静态优化方法; 文献[6]构建考虑相关性的光伏电站群等值功率模型, 同样在利用其持续功率曲线刻画光伏功率长期波动特性的基础上, 建立一种光伏电站群外送输电容量的优化配置方法; 文献[7]利用持续功率曲线建立风电与光热、风电与光伏联合外送容量配置模型。上述研究都是直接将历史风电或光伏输出功率长期波动特性在未来场景下进行应用, 而没有考虑和处理未来场景下风电或光伏发电装机容量的增长导致输出功率长期波动特性改变的问题。

目前针对风电功率短期波动特性的研究较多。文献[8-9]定量分析风电功率波动在不同时间、空间尺度下的分布特性; 文献[10-11]对大规模风电功率波动规律进行研究, 分析多风电场间和风电机组间的平滑效应。在风电功率预测方面的方法较多且研究主要针对恒定装机容量下的风电短期或超短期时序特性。文献[12-14]采用隐马尔科夫链、马尔科夫链蒙特卡洛MCMC(Markov Chain Monte Carlo)法和自回归滑动平均模型ARMA(AutoRegressive Moving Average model)等方法建立多风电场的输出功率时间序列预测模型。然而, 由于在含大规模风电的电力系统规划中, 规划目标年的风电装机容量由当前年的风电装机容量和待建风电场的装机容量构成, 在当前年不可能有新增装机输出功率的历史数据,

收稿日期: 2021-01-12; 修回日期: 2021-09-29

基金项目: 国家重点研发计划项目(2017YFB0902200)

Project supported by the National Key R&D Program of China(2017YFB0902200)

因此无法直接套用现有的风电功率预测方法和风电功率短期波动特性的分析方法。

考虑到规划目标年与当前年的风电装机容量不同,风电功率波动特性受到装机容量的影响,需要对规划期内某一规划目标年的风电功率长期波动特性进行预测。文献[15]利用风电实测数据模拟风电场群的汇聚过程,建立风电场群持续功率的汇聚演变模型,为获取规划目标年的风电场群输出功率长期波动特性提供了思路,但其精度有待进一步提高。

针对上述问题,本文首先对风电功率长期波动特性的刻画方式进行分析并选择最佳的表征方法;其次利用改进核密度估计KDE(Kernel Density Estimation)法和基于遗传算法GA(Genetic Algorithm)寻优的支持向量机SVM(Support Vector Machine)(简称GA-SVM)构建多风电场在各聚合阶段的输出功率概率密度演变预测模型;然后对预测结果进行反演得到规划目标年含待建风电场的多风电场聚合后的持续功率曲线;最后通过工程实例分析证明本文方法的正确性和有效性。

## 1 风电功率长期波动特性预测方法基本原理

本文提出一种基于改进KDE法和GA-SVM预测多风电场聚合后输出功率长期波动特性的方法。

首先,基于在役风电场实测运行数据,综合考虑时序功率曲线、持续功率曲线和数理统计方法,确定风电功率长期波动特性的最佳表征与刻画方式,并揭示多风电场聚合过程中风电功率随装机容量增大的变化规律。

其次,运用改进KDE法计算含多风电场所有可能聚合过程中各装机容量下的输出功率概率密度分布。

然后,结合规划目标年风电场装机容量信息,建立基于SVM的多风电场聚合后规划目标年输出功率概率密度的演变预测模型,其中在优化SVM参数的过程中采用GA进行寻优。

最后,根据多风电场聚合后输出功率的概率分布与持续功率曲线的对应关系,反演出与规划目标年输出功率概率密度相对应的持续功率曲线,并用其表征多风电场聚合后的规划目标年输出功率长期波动特性。

## 2 风电功率长期波动特性的刻画

### 2.1 风电功率长期波动特性的表征方法分析

时序功率曲线可以直观地反映各时刻的风电功率情况,通过计算其差分值来刻画风电功率的短期波动特性,是实现电力系统优化控制和调度的基础,但其无法直观地反映风电场群在一段时间内的输出电量大小和输出功率最大值。

持续功率曲线可以直观地反映发电利用小时数、发电量、风电保证容量、风电功率上限和最大发电小时数等特征指标,便于刻画风电功率的长期波动特性,是对含大规模风电电力系统进行规划的重要工具。基于在役风电场实测运行数据,图1给出了用于描述风电功率长期波动特性的年持续功率曲线。图中,横坐标为年持续时间,纵坐标输出功率为以装机容量为基准的标么值(后同),曲线表示风电输出功率波动特性情况。曲线上点A—D分别表示一年中风电输出功率最大值、输出功率上限值、保证输出功率值和输出功率最小值。根据选择的置信度不同,点B、C的位置会发生变化。E为曲线与坐标轴围成的面积,表示风电等效年满发利用小时数,根据曲线也较易推得风电的年发电量和容量系数等指标。

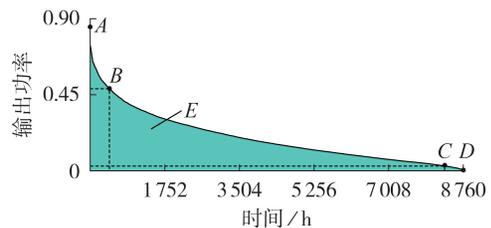


图1 风电的年持续功率曲线

Fig.1 Annual duration power curve of wind power

数理统计法通过计算风电功率的概率分布以及方差、最大值、最小值、差分量等统计量来刻画风电功率的波动特性,而且易于得到风电功率波动特性的量化值,但是由于在制定电力系统规划方案的过程中,需要用到风电输出功率的幅值大小及一定时间内的电量大小来处理电力电量平衡的问题,因此基于数理统计法得到的风电功率波动特性量化值不便于直接用于电力系统规划。

由于准确刻画风电功率概率分布有利于掌握风电功率长期波动情况,因此本文基于在役风电场实测运行数据给出某风电场输出功率概率密度曲线,如图2所示。由图可知,该风电场的输出功率具有低输出功率部分的概率密度高、高输出功率部分的

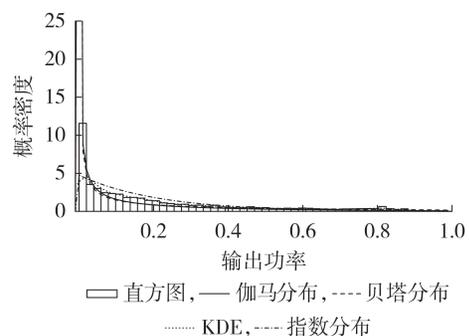


图2 风电功率概率密度曲线

Fig.2 Probability density curves of wind power

概率密度低的特点。

综上,本文采取将数理统计法中的概率分布和持续功率曲线相结合的手段来研究含大规模风电电力系统规划中如何表征和刻画风电功率长期波动性的问题。

## 2.2 多风电场聚合过程中装机容量与风电功率的随动变化关系

由于各风电场的地理位置和装机容量不同以及风资源的时空差异性,多风电场聚合过程中不同阶段都会呈现不同的输出功率波动特性。若采用持续功率曲线法来描述多风电场聚合过程中风电功率随着装机容量增大而表现出的变化规律,则可用式(1)表示。

$$F_{i,j} : S_N^{i,j} \rightarrow P^{i,j} \quad (1)$$

式中: $i=1,2,\dots,I$ 为多风电场聚合过程中的阶段数, $I$ 为聚合阶段总数; $j=1,2,\dots,J$ 为第*i*个聚合阶段参与聚合的风电场数量, $J$ 为风电场总数; $F_{i,j}$ 为第*i*个聚合阶段共计*j*座风电场聚合后从装机容量到风电持续功率向量的映射; $S_N^{i,j}$ 为第*i*个聚合阶段共计*j*座风电场聚合后的总装机容量; $P^{i,j}=[P_1^{i,j}, P_2^{i,j}, \dots, P_Z^{i,j}]^T$ 为第*i*个聚合阶段共计*j*座风电场聚合后的风电持续功率向量, $Z$ 为总持续时间, $P_q^{i,j}(q=1,2,\dots,Z)$ 为第*i*个聚合阶段共计*j*座风电场聚合后持续时间为*q*的风电输出功率。

若采用数理统计法来描述多风电场聚合过程中风电功率概率密度随着装机容量增大而表现出的变化规律,则可用式(2)表示。

$$G_{i,j} : S_N^{i,j} \rightarrow f^{i,j} \quad (2)$$

式中: $G_{i,j}$ 为第*i*个聚合阶段共计*j*座风电场聚合后从装机容量到风电功率概率密度向量的映射; $f^{i,j}=[f_0^{i,j}, f_k^{i,j}, \dots, f_1^{i,j}]^T$ 为第*i*个聚合阶段共计*j*座风电场聚合后输出功率概率密度向量, $k=0,1/M,2/M,\dots,1$ 为风电功率水平,即将多风电场聚合后的输出功率区间 $[0,1]$  p.u.进行*M*等分, $f_k^{i,j}$ 为第*i*个聚合阶段共计*j*座风电场聚合后在第*k*个风电功率水平下的输出功率概率密度。

根据历史负荷数据研究多风电场聚合过程中的持续功率曲线与功率概率密度曲线随着装机容量增大而呈现出的变化关系。其中,在多风电场第*i*个聚合阶段时,通过“装机容量-功率概率密度曲线”的映射关系可得到概率密度曲线,通过“装机容量-持续功率曲线”的映射关系可得到持续功率曲线。数据分析表明,随着参与聚合的风电场数量的增加,各聚合阶段的装机容量逐渐增大,聚合后风电持续功率曲线和功率概率密度曲线逐渐呈现如下非线性变化规律:

1)多风电场聚合过程中风电的持续功率曲线随着装机容量增大呈现头部逐渐降低、中间部分逐渐变宽、尾部逐渐抬高的变化规律;

2)多风电场聚合过程中风电功率概率密度曲线随着装机容量增大呈现头部和尾部逐渐降低、中间部分逐渐抬高的变化规律。

## 3 多风电场聚合过程中不同装机容量的风电功率概率密度曲线生成

针对风资源不确定性导致的风电功率不确定性,采用数理统计法进行分析是有效的,本文利用概率密度曲线进行分析。

鉴于在描述数据分布特性时,KDE法<sup>[16-17]</sup>不依赖于参数估计模型的选择,而且能够有效地避免直方图估计对直方图组距大小和位置的依赖,因此本文采用KDE法生成多风电场聚合过程中不同装机容量的风电功率概率密度曲线。KDE法的表达式为:

$$\hat{f}(p) = \frac{1}{nh} \sum_{m=1}^n K\left(\frac{p-p_m}{h}\right) \quad (3)$$

式中: $\hat{f}(p)$ 为风电功率*p*的KDE函数; $n$ 为样本总数; $h$ 为窗宽; $K(\cdot)$ 为核函数; $p_m$ 为风电功率*p*的第*m*个样本值。

本文选择高斯函数作为核函数,采用经验法则求取窗宽,如式(4)所示。

$$h = 1.06 \sigma n^{-1/5} \quad (4)$$

式中: $\sigma$ 为风电功率样本四分位数。

应用KDE法获取多风电场聚合过程中不同装机容量的风电功率概率密度分布时会存在边界效应的问题,为此,本文利用一种反射的边界修正方法对边界处概率密度估计值进行修正,该方法在添加以边界为轴的反射数据后求取概率密度,以此来修正KDE法在边界区域的边界效应,改进KDE法的表达式为:

$$\hat{f}(p) = \frac{1}{nh} \sum_{m=1}^n \left[ K\left(\frac{(p-p_L)+(p_m-p_L)}{h}\right) + K\left(\frac{p-p_m}{h}\right) + K\left(\frac{(p-p_U)+(p_m-p_U)}{h}\right) \right] \quad (5)$$

式中: $p_L, p_U$ 分别为多风电场聚合后输出功率的下限、上限值。

图3为修正边界效应前、后多风电场聚合后风电功率概率密度估计曲线。由图可以看出,通过KDE法生成的风电功率概率密度曲线在输出功率 $[0,1]$  p.u.的范围之外有非零值,这显然是不合理的,而通过改进KDE法生成的概率密度曲线则修正了该误差。

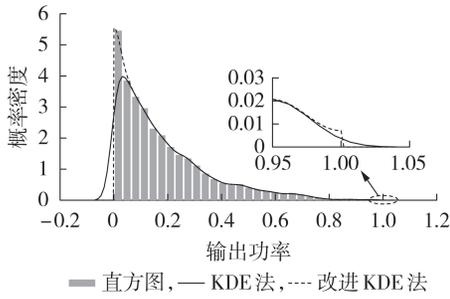


图3 KDE法改进前、后的比较

Fig.3 Comparison between before and after improvement of KDE method

#### 4 建立基于GA-SVM的多风电场聚合后输出功率概率密度演变预测模型

鉴于SVM是基于结构风险最小化原则的有监督学习算法<sup>[18-20]</sup>,在将其用于回归预测时,其基本原理是利用非线性映射将低维输入变量映射到高维空间,构建线性回归模型,以寻找最优超平面,使得所有样本点距离超平面的总偏差最小,因此本文利用多风电场聚合过程中风电功率概率密度曲线随着装机容量增大而变化的规律,采用SVM构建多风电场聚合后输出功率的概率密度演变预测模型。SVM的优化目标函数为:

$$\begin{cases} \min R = \frac{1}{2} \|\mathbf{w}\|^2 + c \sum_{i=1}^n (\xi_i + \xi_i^*) \\ \text{s.t. } y_i - \mathbf{w}\varphi(x_i) - b_i \leq \varepsilon + \xi_i \\ \mathbf{w}\varphi(x_i) + b_i - y_i \leq \varepsilon + \xi_i^* \\ \xi_i \geq 0, \xi_i^* \geq 0 \end{cases} \quad (6)$$

式中: $R$ 为优化目标变量; $\mathbf{w}$ 、 $b_i$ 为最优超平面参数, $\mathbf{w}$ 为权重向量, $b_i$ 为第 $t$ 个时刻的偏移量; $c$ 为惩罚因子; $\varepsilon$ 为不敏感损失函数; $\xi_i$ 、 $\xi_i^*$ 为第 $t$ 个时刻的松弛因子,有如式(7)所示关系; $x_i$ 、 $y_i$ 分别为训练样本在第 $t$ 个时刻输入、输出值; $\varphi(\cdot)$ 为SVM的核函数。

$$\xi_i^* = \begin{cases} 0 & |\xi_i| < \varepsilon \\ |\xi_i| - \varepsilon & |\xi_i| \geq \varepsilon \end{cases} \quad (7)$$

基于改进KDE法生成的多风电场所有可能聚合过程中各装机容量下的输出功率概率密度样本,并依据聚合过程中各功率水平下风电功率概率密度的变化规律,将多风电场聚合后第 $i+1$ 个阶段的总装机容量 $S_N^{i+1}$ 和其前 $l$ ( $l$ 为GA-SVM模型输入嵌入维数)个阶段的输出功率概率密度值作为SVM的输入,将多风电场聚合后第 $i+1$ 个阶段风电功率概率密度值作为SVM的输出,从而构建出多风电场聚合后输出功率概率密度演变预测模型,如式(8)所示。

$$f_k^*(S_N^{i+1}) = g(f_k(S_N^{i-l+1}), \dots, f_k(S_N^{i-1}), f_k(S_N^i), S_N^{i+1}) \quad (8)$$

式中: $f_k^*(S_N^{i+1})$ 为多风电场在第 $i+1$ 个聚合阶段装

容量为 $S_N^{i+1}$ 时,风电在输出功率水平为 $k$ 下的功率概率密度预测值; $g(\cdot)$ 为GA-SVM模型; $S_N^i$ 、 $S_N^{i-1}$ 、 $\dots$ 、 $S_N^{i-l+1}$ 分别为多风电场聚合过程中第 $i$ 个阶段及其前 $l-1$ 个阶段的装机容量; $f_k(S_N^i)$ 、 $f_k(S_N^{i-1})$ 、 $\dots$ 、 $f_k(S_N^{i-l+1})$ 为输出功率水平 $k$ 下各聚合阶段装机容量对应的风电功率概率密度值。当第 $i+1$ 个聚合阶段装机容量 $S_N^{i+1}$ 为规划目标年装机容量时,预测结果即为规划目标年多风电场聚合后输出功率概率密度曲线。

本文选择径向基核函数作为SVM的核函数,并利用GA对SVM的参数进行寻优。

#### 5 风电功率概率密度分布反演持续功率曲线

对多风电场聚合后在规划目标年的风电功率概率密度分布预测结果进行积分,得到风电功率概率分布曲线,即多风电场聚合后风电功率在 $[0, 1]$  p.u.区间内不同功率水平的概率值,利用式(9)可计算出多风电场聚合后在规划目标年内不同功率水平的风电功率持续时间,最后将对应输出功率值降序排列即可得到持续功率曲线。

$$t_k = [P_k Z] \quad (9)$$

式中: $t_k$ 为多风电场聚合后风电功率水平为 $k$ 时的持续时间; $P_k$ 为风电功率水平为 $k$ 时的概率值; $[\cdot]$ 表示就近取整。

#### 6 实例分析

以我国西北某省已经投运的22座风电场为例,对多风电场聚合后规划目标年风电功率长期波动特性进行预测。附录A图A1给出了该地区风电场的分布及其接入站点信息,可以看出风电场分布范围广且不均衡。

本文将首先建成的17座风电场(总装机容量为1406.5 MW)的建设年份作为历史年,并将这17座风电场的实测风电运行数据和装机容量作为建模域;将22座风电场(总装机容量为1903 MW)均建成的年份作为规划目标年,并将这22座风电场的实测风电运行数据和装机容量作为预测域。根据风电总装机容量在达到1406.5 MW前各历史年风电功率长期波动特性随装机容量逐渐增大呈现的变化规律,利用所提方法预测风电总装机容量达到1903 MW时规划目标年输出功率的长期波动特性。

在建模域中以每个历史年中建设的风电场参与聚合的次序和阶段为例,来说明多风电场在逐步聚合的过程中输出功率随装机容量增大而变化的规律性,如表1所示。

各聚合阶段的风电持续功率曲线如图4所示。利用改进KDE法生成的对应概率密度曲线见图5。

利用式(1)~(9)实现基于改进KDE法和GA-

表 1 多风电场各汇聚阶段对应的总装机容量  
Table 1 Total installed capacity of multiple wind farms at each convergence stage

历史年	聚合阶段	投运风电场	总装机容量 / MW
$Y_0$	初始阶段	$W_1$	99.5
$Y_1$	第二阶段	$W_2 \sim W_6$	397.5
$Y_2$	第三阶段	$W_7 \sim W_{11}$	694.5
$Y_3$	第四阶段	$W_{12}$	1092.5
$Y_4$	第五阶段	$W_{13}$	1191.5
$Y_5$	第六阶段	$W_{14}、W_{15}$	1341.5
$Y_6$	第七阶段	$W_{16}、W_{17}$	1406.5

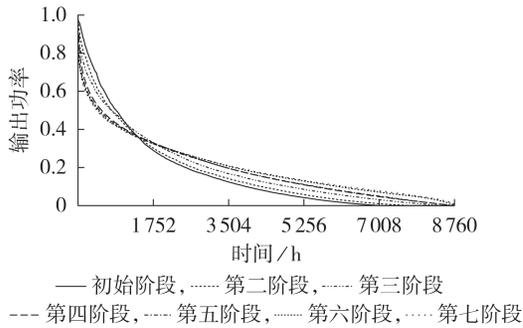


图 4 多风电场聚合过程中不同装机容量下的风电持续功率曲线

Fig.4 Duration power curves of wind power during aggregation process of multiple wind farms under different installed capacities

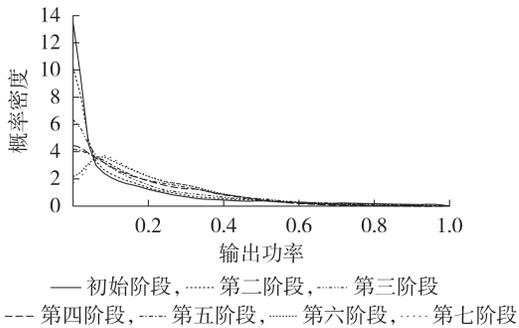


图 5 多风电场聚合过程中不同装机容量下的风电功率概率密度曲线

Fig.5 Probability density curves of wind power during aggregation process of multiple wind farms under different installed capacities

SVM 的多风电场聚合后规划目标年风电功率长期波动特性预测方法。其中,GA 迭代次数为 100 次,种群规模为 20 个,惩罚因子  $c$  的取值范围为  $[0, 100]$ ,核函数参数  $\gamma$  的取值范围为  $[0.01, 10]$ 。优化目标选择为训练集的交叉验证误差最小,  $K$ -折交叉验证  $K$ -CV ( $K$ -fold Cross Validation) 参数为 5 折。经过多次试验,GA-SVM 模型输入嵌入维数  $l$  为 5,风电功率区间等分数  $M$  取 500,总持续时间  $Z$  取 8760 h。另外,为了能够在保证结果合理的基础上节省 SVM 训练时间,将接入场站相同的风电场聚合成一个等效风电场群。为避免建模域中由于多风电场聚合顺序

的特定选择可能给规划目标年预测结果带来的不利影响,综合考虑建模域 17 座风电场所有可能的聚合顺序,将等效后的风电场按排列组合方法进行聚合,模拟多风电场聚合发展过程建立建模域样本,并对装机容量相同的样本进行合并,化简样本容量,根据聚合后呈逐渐递增趋势的风电装机容量序列长度确定聚合阶段总数  $I$ ,得到建模域样本容量。

利用式(7)计算得到多风电场聚合后规划目标年的风电功率概率密度曲线,如附录 A 图 A2 中红色曲线所示。采用前馈型反向传播 BP (Back Propagation) 神经网络和反馈型 Elman 神经网络作为对比,对与 GA-SVM 模型相同的风电功率概率密度样本进行训练和预测,通过试值法设置 BP 神经网络和 Elman 神经网络的输入层、隐含层和输出层节点数分别为 6、4、1,训练次数为 1000 次,学习率为 0.01,训练函数为 trainlm 方法。采用各方法得到多风电场聚合后规划目标年的风电功率概率密度曲线,如附录 A 图 A2 所示。各方法的预测精度对比如表 2 所示。

表 2 概率密度预测精度评估结果

Table 2 Evaluation results of prediction accuracy for probability density

方法	误差平方和	均方误差	均方根误差	确定系数
GA-SVM	9.7968	0.0196	0.1400	0.8995
BP	32.0045	0.0640	0.2530	0.8183
Elman	21.8113	0.0436	0.2089	0.8500

由附录 A 图 A2 和表 2 可知,相比于 BP、Elman 神经网络,采用结构风险最小化的 GA-SVM 得到的多风电场聚合后输出功率概率密度曲线的预测结果误差明显更小,预测精度明显更高。

通过式(8)对 GA-SVM 预测出的规划目标年风电功率概率密度进行反演,得到多风电场聚合后规划目标年风电的持续功率曲线,如图 6 所示。图 6 中同时给出了最小二乘趋势外推的线性回归法的预测曲线以及实测的风电持续功率曲线进行对比。

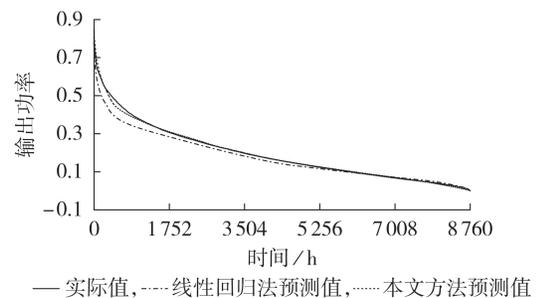


图 6 多风电场聚合后规划目标年风电持续功率曲线预测结果

Fig.6 Prediction results of duration power curves of wind power for multiple wind farms after aggregation in planning target year

附录 A 图 A3 给出了通过 2 种方法得到的多风

电场聚合后规划目标年风电持续功率曲线的预测误差曲线。采用均方根误差和平均绝对误差评价不同方法的预测效果,如表3所示,表中均方根误差、平均绝对误差、最大绝对误差均为标么值。

表3 误差指标对比

方法	均方根误差	平均绝对误差	最大绝对误差	年最大发电小时数 相对误差/%
本文方法	0.0079	0.0045	0.0350	0.066
线性回归法	0.0283	0.0186	0.0876	8.500

由图6、附录A图A3和表3可知,本文提出的基于改进KDE法和GA-SVM的多风电场聚合后输出功率长期波动特性预测方法,在评价预测结果的4个误差指标方面均远优于最小二乘趋势外推的线性回归法。

此外,对KDE法改进前、后对规划目标年多风电场聚合后输出功率长期波动特性预测结果的影响进行分析。采用KDE法建立多风电场聚合过程中输出功率概率密度样本,同样利用GA-SVM采用相同预测模型进行预测,KDE法改进前、后的预测结果如图7和图8所示。

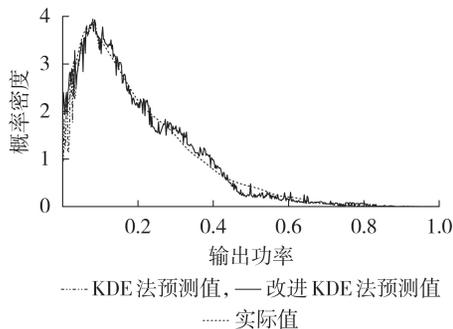


图7 风电功率概率密度预测曲线对比

Fig.7 Comparison of predicted probability density curves for wind power

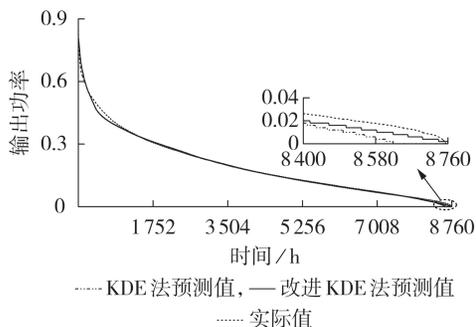


图8 KDE法改进前、后持续功率曲线预测结果对比  
Fig.8 Comparison of prediction results of duration power curves between before and after improvement of KDE method

由图7和图8可知,在求取风电功率概率密度分布时采用改进KDE法可有效解决边界效应问题。

KDE法改进前、后最大发电小时数预测绝对误差分别为237 h和5 h,年满发利用小时数预测绝对误差分别为12 h和1 h,可见改进KDE法有效提高了预测精度。

## 7 结论

本文提出一种用于预测规划目标年多风电场聚合后输出功率长期波动特性的方法,得到如下结论。

1)揭示了多风电场聚合后输出功率长期波动特性随着装机容量的增大而呈现的非线性变化规律。突破了传统风电功率预测方法必须在装机容量一定的情况才能使用的约束条件,为实现在风电装机容量发生变化的未来年场景下有效预测风电功率长期波动特性奠定了理论基础。

2)给出了一种在没有新建风电场输出功率数据的情况下,准确刻画规划目标年含新建风电场的多风电场聚合后输出功率长期波动变化特性的方法。

3)在利用改进KDE法和GA-SVM预测多风电场聚合后规划目标年的风电功率长期波动特性的过程中,采用持续功率曲线法和数理统计法相结合的方法,该方法更适用于表征和刻画含大规模风电的电力系统规划中风电功率长期波动特性,与现有方法相比,本文方法具有更高的预测精度。

鉴于规划期风电场建设的容量、位置和数量等因素都会对规划目标年风电功率长期波动特性预测精度产生影响,笔者计划下一步对计及这些因素的风电功率长期波动特性开展深入研究。

附录见本刊网络版(<http://www.epae.cn>)。

## 参考文献:

- [1] 薛禹胜,雷兴,薛峰,等. 关于风电不确定性对电力系统影响的评述[J]. 中国电机工程学报,2014,34(29):5029-5040.  
XUE Yusheng, LEI Xing, XUE Feng, et al. A review on impacts of wind power uncertainties on power systems[J]. Proceedings of the CSEE,2014,34(29):5029-5040.
- [2] 姜文玲,王勃,汪宁渤,等. 多时空尺度下大型风电基地出力特性研究[J]. 电网技术,2017,41(2):493-499.  
JIANG Wenling, WANG Bo, WANG Ningbo, et al. Research on power output characteristics of large-scale wind power base in multiple temporal and spatial scales[J]. Power System Technology,2017,41(2):493-499.
- [3] 黄林宏,宋丽莉,周荣卫,等. 大型风电基地风电波动特征分析[J]. 中国电机工程学报,2017,37(6):1599-1610.  
HUANG Linhong, SONG Lili, ZHOU Rongwei, et al. Characteristics analysis of wind power fluctuations for large-scale wind farms[J]. Proceedings of the CSEE,2017,37(6):1599-1610.
- [4] 李剑楠,乔颖,鲁宗相,等. 大规模风电多尺度出力波动性的统计建模研究[J]. 电力系统保护与控制,2012,40(19):7-13.  
LI Jiannan, QIAO Ying, LU Zongxiang, et al. Research on statistical modeling of large-scale wind farms output fluctuations in different spacial and temporal scales[J]. Power System Protection and Control,2012,40(19):7-13.
- [5] 穆钢,崔杨,严干贵. 确定风电场群功率汇聚外送输电容量的

- 静态综合优化方法[J]. 中国电机工程学报,2011,31(1):15-19.
- MU Gang, CUI Yang, YAN Gangui. A static optimization method to determine integrated power transmission capacity of clustering wind farms[J]. Proceedings of the CSEE, 2011, 31(1):15-19.
- [6] 崔杨,李焕奇,严干贵,等. 计及汇聚特性的光伏电站群集中外送输电容量优化配置方法[J]. 电网技术,2015,39(12):3491-3496.
- CUI Yang, LI Huanqi, YAN Gangui, et al. An optimization method to determine integrated power transmission capacity of clustering photovoltaic plants based on clustering effect[J]. Power System Technology, 2015, 39(12):3491-3496.
- [7] 崔杨,张汇泉,仲悟之,等. 基于分时能量互补的风电-光热联合外送容量优化配置方法[J]. 电网技术,2019,43(11):3875-3882.
- CUI Yang, ZHANG Huiquan, ZHONG Wuzhi, et al. An optimization method to determine power delivery capacity of combined wind-CSP system based on time-sharing energy complementation[J]. Power System Technology, 2019, 43(11):3875-3882.
- [8] 杜刚,赵冬梅,刘鑫,等. 基于重尾分布的风电功率波动特性概率分布[J/OL]. 电力自动化设备. [2021-07-17]. <https://doi.org/10.16081/j.epae.202104003>.
- [9] 林卫星,文劲宇,艾小猛,等. 风电功率波动特性的概率分布研究[J]. 中国电机工程学报,2012,32(1):38-46,20.
- LIN Weixing, WEN Jinyu, AI Xiaomeng, et al. Probability density function of wind power variations[J]. Proceedings of the CSEE, 2012, 32(1):38-46, 20.
- [10] 申颖,赵千川,李明扬. 多时空尺度下风电平滑效应的分析[J]. 电网技术,2015,39(2):400-405.
- SHEN Ying, ZHAO Qianchuan, LI Mingyang. Analysis on wind power smoothing effect in multiple temporal and spatial scales[J]. Power System Technology, 2015, 39(2):400-405.
- [11] 刘燕华,田茹,张东英,等. 风电出力平滑效应的分析与应用[J]. 电网技术,2013,37(4):987-991.
- LIU Yanhua, TIAN Ru, ZHANG Dongying, et al. Analysis and application of wind farm output smoothing effect[J]. Power System Technology, 2013, 37(4):987-991.
- [12] 管霖,周保荣,文博,等. 多风电场功率时间序列的时空相关性统计建模和运行模拟方法[J]. 电网技术,2021,45(1):30-39.
- GUAN Lin, ZHOU Baorong, WEN Bo, et al. Spatiotemporal correlation statistic modeling and simulation in multiple wind farm power sequence[J]. Power System Technology, 2021, 45(1):30-39.
- [13] 李湃,刘纯,黄越辉,等. 基于隐马尔科夫模型的多风电场相关性出力时间序列建模方法[J]. 中国电机工程学报,2019,39(19):5683-5691,5896.
- LI Pai, LIU Chun, HUANG Yuehui, et al. Modeling correlated power time series of multiple wind farms based on hidden Markov model[J]. Proceedings of the CSEE, 2019, 39(19):5683-5691, 5896.
- [14] 黄越辉,曲凯,李驰,等. 基于K-means MCMC算法的中长期风电时间序列建模方法研究[J]. 电网技术,2019,43(7):2469-2476.
- HUANG Yuehui, QU Kai, LI Chi, et al. Research on modeling method of medium-and long-term wind power time series based on K-means MCMC algorithm[J]. Power System Technology, 2019, 43(7):2469-2476.
- [15] 穆钢,杨修宇,严干贵,等. 基于风电场群汇聚演变趋势的场群持续功率特性预测方法[J]. 中国电机工程学报,2018,38(增刊1):32-38.
- MU Gang, YANG Xiuyu, YAN Gangui, et al. Prediction method of the durative characteristic for wind farm cluster based on cumulative evolution tendency[J]. Proceedings of the CSEE, 2018, 38(Supplement 1):32-38.
- [16] 杨楠,崔家展,周峥,等. 基于模糊序优化的风功率概率模型非参数核密度估计方法[J]. 电网技术,2016,40(2):335-340.
- YANG Nan, CUI Jiazhan, ZHOU Zheng, et al. Research on nonparametric kernel density estimation for modeling of wind power probability characteristics based on fuzzy ordinal optimization[J]. Power System Technology, 2016, 40(2):335-340.
- [17] 赵书强,胡利宁,田捷夫,等. 基于中长期风电光伏预测的多能源电力系统合约电量分解模型[J]. 电力自动化设备,2019,39(11):13-19.
- ZHAO Shuqiang, HU Lining, TIAN Jiefu, et al. Contract power decomposition model of multi-energy power system based on mid-long term wind power and photovoltaic electricity forecasting[J]. Electric Power Automation Equipment, 2019, 39(11):13-19.
- [18] 杨茂,刘慧宇,孙勇,等. 基于原子稀疏分解和支持向量机的风电功率实时预测研究[J]. 东北电力大学学报,2020,40(3):1-7.
- YANG Mao, LIU Huiyu, SUN Yong, et al. A study on real-time prediction of wind power based on atomic sparse decomposition and support vector machine[J]. Journal of Northeast Electric Power University, 2020, 40(3):1-7.
- [19] 田书欣,周全,程浩忠,等. 基于鸽群优化算法的支持向量机在电力需求总量预测中的应用[J]. 电力自动化设备,2020,40(5):173-181.
- TIAN Shuxin, ZHOU Quan, CHENG Haozhong, et al. Application of pigeon-inspired optimization algorithm based SVM in total power demand forecasting[J]. Electric Power Automation Equipment, 2020, 40(5):173-181.
- [20] 刘俐,李勇,曹一家,等. 基于支持向量机和长短期记忆网络的暂态功角稳定预测方法[J]. 电力自动化设备,2020,40(2):129-139.
- LIU Li, LI Yong, CAO Yijia, et al. Transient rotor angle stability prediction method based on SVM and LSTM network[J]. Electric Power Automation Equipment, 2020, 40(2):129-139.

#### 作者简介:



肖白

肖白(1973—),男,吉林吉林人,教授,博士,主要从事电力系统规划、空间电力负荷预测、多能源电力系统互补协调发电、继电保护等方面的研究与教学工作(**E-mail**:xbxiaobai@126.com);

邢世亨(1996—),男,吉林德惠人,硕士,主要从事含高比例可再生能源发电的电力系统规划方面的研究工作(**E-mail**:2297861852@qq.com);

王茂春(1982—),男,青海西宁人,高级工程师,硕士,主要从事电网调度运行和多种能源互补协调发电方面的研究工作(**E-mail**:840974042@qq.com);

杨森林(1975—),男,河南西平人,高级工程师,硕士,主要从事输变电施工技术和新技术的推广应用工作(**E-mail**:1356976345@qq.com);

苟晓侃(1984—),男,甘肃泰安人,高级工程师,硕士,主要从事智能电网技术和新技术的推广工作(**E-mail**:qdxgkxk@163.com)。

(编辑 王锦秀)

## Prediction method of output power long-term fluctuation characteristic for multiple wind farms after aggregation based on improved KDE method and GA-SVM

XIAO Bai<sup>1</sup>, XING Shiheng<sup>2</sup>, WANG Maochun<sup>3</sup>, YANG Senlin<sup>3</sup>, GOU Xiaokan<sup>3</sup>

(1. School of Electrical Engineering, Northeast Electric Power University, Jilin 132012, China;

2. Yanbian Power Supply Company of State Grid Jilin Electric Power Supply Co., Ltd., Yanji 133000, China;

3. State Grid Qinghai Electric Power Company, Xining 810008, China)

**Abstract:** Aiming at the problem that there exists new-added wind power installed capacity during the planning period but its corresponding measured wind power output data is lacked, which causes the long-term fluctuation characteristic of output power of multiple wind farms after aggregation in the planning target year is difficult to be accurately grasped and described, a prediction method for long-term fluctuation characteristic of output power of multiple wind farms after aggregation is proposed based on improved KDE (Kernel Density Estimation) method and GA-SVM (Support Vector Machine optimized by Genetic Algorithm). The long-term fluctuation characteristic of output power of wind power is described, and the relationship between installed capacity and wind power is analyzed during the aggregation process of multiple wind farms. The improved KDE method is used to generate the probability density curves of output power during the aggregation process of multiple wind farms with different installed capacities. GA-SVM is adopted to establish the probability density varying model of output power after aggregation of multiple wind farms. According to the corresponding relationship between probability distribution and duration power curve, the predicted probability density curve of output power for multiple wind farms after aggregation in the planning target year is inversed so that the duration power curve which can describe the long-term fluctuation characteristic of output power in the planning target year is obtained. Engineering project verifies the practicability and effectiveness of the proposed method.

**Key words:** multiple wind farms; wind power fluctuation characteristic; kernel density estimation; support vector machine

(上接第62页 continued from page 62)

## Modeling and control method for large-scale electric vehicle clusters

AN Haiyun<sup>1</sup>, WANG Mingshen<sup>1</sup>, WANG Weiliang<sup>2</sup>, DONG Xiaohong<sup>3</sup>, MENG Jian<sup>4</sup>, HUANG Cheng<sup>1</sup>

(1. Electric Power Research Institute of State Grid Jiangsu Electric Power Co., Ltd., Nanjing 211103, China;

2. Maintenance Branch of State Grid Jiangsu Electric Power Co., Ltd., Nanjing 211100, China;

3. State Key Laboratory of Reliability and Intelligence of Electrical Equipment,  
Hebei University of Technology, Tianjin 300130, China;

4. State Grid Economic and Technology Research Institute, Beijing 102209, China)

**Abstract:** The extensive access of renewable energy has a profound impact on the system source-load balance. The large-scale grid-connected EV (Electric Vehicle) clusters have rapid and considerable adjustable potential, which can provide power regulation support for the system source-load balance. The existing modeling and control methods of large-scale EV clusters need to simulate the response characteristics of each independent EV and develop independent control signals, and the model complexity is high and the computation is large. At the same time, a large number of control signals will increase the real-time communication pressure and have high requirements for communication facilities. To solve the above problems, a simplified modeling and control method for large-scale EV clusters is proposed. Firstly, the response characteristics of a single EV are fully analyzed, and three access states and four response modes are proposed. Then, finite state sub-intervals are used to describe the state distribution of large-scale EV clusters, and the output power and adjustable capacity of EV clusters are evaluated. By changing the state distribution of EVs in sub-intervals, four response modes are realized. Finally, a control signal composed of two probability values is designed to reduce the complexity of the control method, and the requirement for communication is reduced by controlling all EVs to receive the same probability signals. Simulative results of an example verify the effectiveness of the proposed modeling and control method.

**Key words:** electric vehicle clusters; modeling; control method; probabilistic control; response characteristics

附录 A :

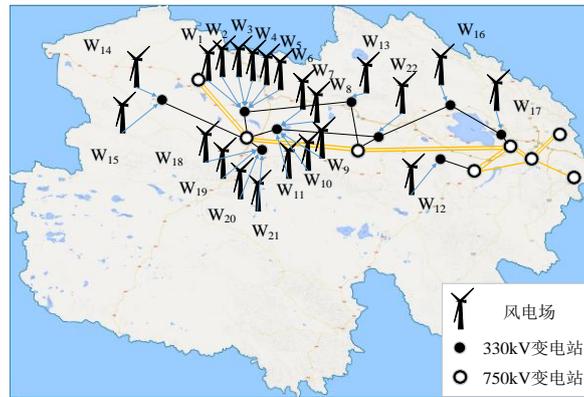


图 A1 西北某省风电场分布示意图

Fig.A1 Sketch map of wind farms' distribution in a northwest province

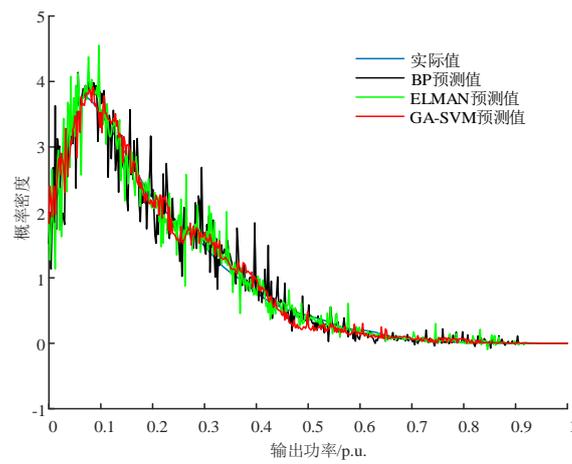


图 A2 多风电场聚合后规划目标年风电功率概率密度预测曲线

Fig.A2 Predicted probability density curve of wind power after aggregation of multiple wind farms in planning target year

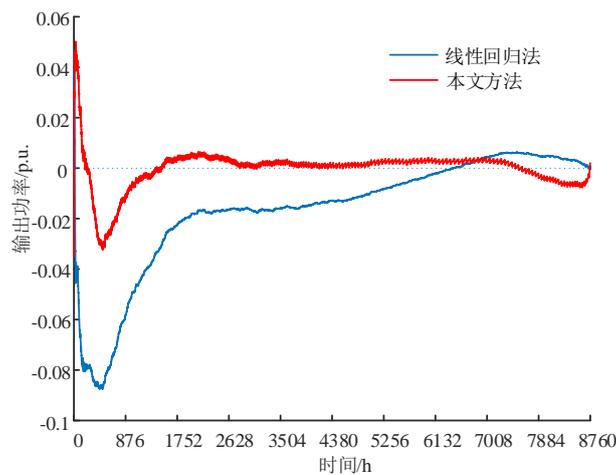


图 A3 预测误差曲线

Fig.A3 Prediction error curves