

基于模糊集鲁棒概率不等式的风电斜坡估计方法

徐姣新¹ 杨 召²

¹(商丘学院 河南 商丘 476000)

²(商丘工学院 河南 商丘 476000)

摘要 从不确定性量化的角度将风电出力的斜坡事件发生概率转化为一个数据驱动的鲁棒概率不等式,该不等式提供一个随机变量的概率,且其概率分布属于给定的多面体。为了解决风电输出的分布不确定性问题,考虑由可用数据构造的模糊集合中的候选分布集合,其最低要求是要包括预测值和平均绝对偏差。基于矩的模糊集由所有概率分布组成,共享相同的平均和平均绝对偏差值。当已知更多历史数据时,可以建立一个基于散度的模糊集,该模糊集包含所有接近 Wasserstein 度量意义上经验分布的概率分布。该方法提供最坏情况下的风电功率分布中斜坡事件的概率上限,历史数据越多,其保守性还可以显著降低。最后将所提方法与高斯混合模型进行比较,验证其有效性和优越性。

关键词 数据驱动优化 预测 斜坡事件 不确定性 风力发电

中图分类号 TP301.6

文献标志码 A

DOI:10.3969/j.issn.1000-386x.2022.03.018

WIND POWER SLOPE ESTIMATION METHOD BASED ON FUZZY SET ROBUST PROBABILITY INEQUALITY

Xu Jiaoxin¹ Yang Zhao²

¹(Shangqiu University, Shangqiu 476000, Henan, China)

²(Shangqiu Institute of Technology, Shangqiu 476000, Henan, China)

Abstract From the perspective of uncertainty quantification, the probability of slope event of wind power output is transformed into a data-driven robust probability inequality, which provides the probability of a random variable and its probability distribution belongs to a given polyhedron. In order to solve the distribution uncertainty problem of wind power output, this paper considers the candidate distribution set in the fuzzy set constructed by available data. The minimum requirement is to include the predicted value and the average absolute deviation. The moment-based fuzzy set consists of all probability distribution, sharing the same mean and mean absolute deviation values. When more historical data is known, a fuzzy set based on divergence can be established, which contains all probability distributions close to the empirical distribution in the sense of Wasserstein metric. This method provides the upper limit of probability of slope events in the worst-case wind power distribution. The more historical data, the less conservative it is. Finally, the proposed method is compared with Gaussian mixture model to verify its effectiveness and superiority.

Keywords Data driven optimization Prediction Slope event Uncertainty Wind power generation

0 引言

在向绿色和可持续发展社会过渡的过程中,风电在世界范围内得到了快速发展。然而,由于天气条件

的原因,风力发电本质上是随机的。由于电力系统必须在瞬间平衡负荷,短期内电力输出的大幅度变化(称为风电斜坡事件^[1])将给电力系统运行带来巨大挑战。根据方向,风电斜坡事件可以分为两类:向上斜坡和向下斜坡。向上斜坡事件通常由强低压空气系

统、阵风、低空急流和雷暴引起。相反情形下,上述现象的逆转,便会发生向下的斜坡事件^[2]。在向上斜坡事件中,系统调度员必须减少常规发电机的功率输出或减少一些风力发电;在向下斜坡事件中,调度员则需要备用容量的支持,或在备用容量不足时减少一些负荷^[3]。所有这些斜坡事件都会增加系统运营成本和风险,因此,更好地检测和预测风电斜坡事件可以警告调度员,并帮助他们部署预防风险故障的主动策略。

风力发电斜坡事件的检测作为一项重要的技术,一直是众多学者研究的热点。文献[4]提出了一种基于澳大利亚风力发电预测工具(Wind power prediction tool, WPPT)风电场数据的两阶段方法来检测和分类大型风坡道。文献[5]提出了一种基于支持向量机(Support vector machine, SVM)的风力发电斜坡事件一步分类和多步分类模型。文献[6]提出了一种用于识别大时间序列风坡的最优检测技术,给出了一类带有斜坡定义的评分函数,并应用动态规划递归方法检测斜坡事件。文献[7]采用一种摆动门算法(Swinging door algorithm, SDA)从历史数据中识别斜坡事件,该方法只需定义一个参数,在计算效率和抗噪声方面具有显著优势。

基于斜坡检测技术的斜坡预测技术可以在几分钟或几小时之前提供警告信息,并帮助调度员提前安排系统操作。通常,风电斜坡事件的预测可分为两类:确定性预测和概率性预测。对于前者,文献[8]提出了一个基于数据挖掘算法的多变量时间序列模型来预测风电爬坡率。文献[9]提出了一种基于多数值天气预报(Numerical weather prediction, NWP)输入、统计处理和自适应算法的时间斜坡预测模型。

值得注意的是,上述研究依赖于确定性范式,而忽略了风坡事件的不确定性问题。采用概率方法提供风坡道的统计信息,可以帮助系统运营商做出更好的调度决策,以应对这些风险事件。部分研究提出利用大时间尺度信息建立概率风坡预测模型,或采用自回归对数模型,以基于多项式对数结构和分类分布同时估计不同阈值的斜坡事件概率。在应对斜坡坡度和相位预测误差问题时,可以使用短期斜坡预测模型,对风电功率进行概率密度估计,然后利用概率密度函数提供遇到斜坡事件的概率信息。

上述概率方法基于风电的经验分布进行统计分析。然而,一方面,校准一个精确的概率分布需要足够的历史数据,而这些数据可能不是可用的;另一方面,任何参数分布可能都不完全适合真实数据,导致统计

分析对不确定数据分布的变化很敏感。克服上述困难的一种方法是采用分布鲁棒优化方法,该方法考虑了经验分布周围的一系列分布,其结果提供了对目标事件概率的保守估计,并且对概率分布中的扰动具有鲁棒性。

在分布鲁棒优化模型中,采用概率密度函数(Probability density function, PDF)描述事件的不确定性,但PDF是不精确的,考虑将一系列候选PDF构成所谓的模糊集。根据已知信息,可以用两种方法构造模糊集。一种是使用力矩信息,另一种是采用经验分布和散度量。本文从不确定性量化的角度研究了风电斜坡事件的概率预测^[10],提出具有两个模糊集的鲁棒概率不等式来估计斜坡事件的概率。其中,第一个模糊集只需要点预测和预测误差的平均绝对偏差,并考虑预测误差分布的单峰性;第二个模糊集需要任意数量的风电历史数据。两种模型都是数据驱动的,得到可解的凸优化问题,通过离线求解器进行求解。

1 所提方法描述

1.1 不确定性量化模型

风力发电斜坡事件发生在与输电网相连的大型风电场中。现有文献以几种方式定义斜坡事件,在文献[1,12]中,是指风电场在多个时期内的巨大变化(如30分钟或1小时内达到20%的容量),或在短时期内的快速变化率。文献[1]中,多个时段的最大和最小风力之间的差异也被视为斜坡事件。

本文研究了文献[1]中定义的单周期爬坡的超短期预测问题:连续两个调度周期(通常为1小时)的风电变化超过一个阈值。假设未来两个连续时段的点风电预测可用,应用文献[10]中的方法,很容易识别风电输出的增量变化,从而以确定的方式检测斜坡事件。然而,点预测存在不精确性,可以为系统调度员提供保守或乐观的结果。具有置信水平信息的概率斜坡预测是理想的,如文献[11]中的条件区间预测方法。然而,由于一个斜坡事件包含两个不同时段的数据,这两个时段都是不确定的,因此很难从条件区间预测方法中提取风电动态。

图1给出了潜在的斜坡事件表示,时段1和时段2的点预测分别为 w_1^o 和 w_2^o ,确定性方法将差值 $w_1^o - w_2^o$ 与预先指定的阈值进行比较以判断斜坡事件。然而,由于这两个值都是不确定的,且都属于两个特定的区间,因此实际的增量变化可能大于或小于 $w_1^o - w_2^o$,这会影响到结果的可信度,在最坏的情况下,偏差 $w_1^o -$

w_2^l 会构成更严重的斜坡事件。基于此,本文重点考虑了 w_1 和 w_2 的不确定性问题,不假设预测误差的准确概率分布,而是充分利用有限数据中的分布信息,对斜坡事件的概率进行保守估计。




图1 风电斜坡事件描述

设 $\mathbf{w} = [w_1, w_2]^T$ 为随机变量的向量, $f(\mathbf{w})$ 为其概率密度函数(PDF),向上斜坡事件的概率可以表示为:

$$\Pr\{\mathbf{w} \in W\} \quad (1)$$

式中: $\Pr[\cdot]$ 代表事件发生的概率,且:

$$W = \left\{ \mathbf{w} \left| \begin{array}{l} 0 \leq w_1 \leq C \\ 0 \leq w_2 \leq C \\ w_2 - w_1 \geq R_U \end{array} \right. \right\} \quad (2)$$

式中: C 表示风电场的容量; R_U 表示向上斜坡阈值。将最后一个约束替换为 $w_1 - w_2 \geq R_D$ 即可以类似的方式设置向下斜坡事件的概率,其中 R_D 表示向下斜坡阈值。

评估式(1)中的概率需要用到 \mathbf{w} 的 PDF,一般假设 \mathbf{w} 服从高斯分布,并通过曲线拟合方法估计均值和方差。然而,这样的参数分布可能无法反映风电的真实分布情况。为了克服 PDF 获取困难的问题,本文提出考虑一类不确定的 PDF,并将其限制在一个模糊集 S 内,目的是找出最不利的结果,从而得到以下分布的鲁棒不确定性量化问题:

$$\sup_{f(\mathbf{w}) \in S} \Pr\{\mathbf{w} \in W\} \quad (3)$$

这一问题对应一个概率不等式,可以转化为函数优化问题求解。 $\Pr[\cdot]$ 定义了从 PDF $f(\mathbf{w})$ 到实数的映射,决策变量是 $f(\mathbf{w})$,是实值函数。换句话说,对于每一个 $\mathbf{w} \in W$, $f(\mathbf{w})$ 是一个决策变量,决策变量的数目是无限的,可行域是 S 。如果 \mathbf{w} 服从 S 中包含的任何分布,则斜坡事件的实际概率应不大于式(3)的最优值。这种保守的估计可以在 PDF 扰动的前提下保持足够的安全裕度,因此在电力系统运行中是可以接受的。

1.2 基于矩的方法

如果所有 Borel 集 $B \in B(\mathbf{R}^k)$ 的 $t^k f(B - m/t)$ 在 $t > 0$ 时不递减,则 $\mathbf{w} \in \mathbf{R}^k$ 的概率分布 $f(\mathbf{w}) \in S$ 是中心为 m 的单峰分布。

$$S_1 = \left\{ f(\mathbf{w}) \left| \begin{array}{l} E_f(\mathbf{w}) = m, E_f(|\mathbf{w} - m|) = \sigma \\ f \text{ 是以 } m \text{ 为中心的单峰函数} \end{array} \right. \right\} \quad (4)$$

基于矩的模糊集 S_1 考虑了所有具有相同平均值 m 和平均绝对偏差 σ 的偏微分方程,此外,要求 PDF $f(\mathbf{w})$ 单峰。

将 S_1 代入式(3),得到的不确定量化问题可以重新表述为以下形式^[12]:

$$\inf 1 - \lambda + \sigma^T \eta \quad (5)$$

$$\left\{ \begin{array}{l} \lambda \in \mathbf{R}, \theta \in \mathbf{R}^2, \eta \in \mathbf{R}_+^2, \pi \in \mathbf{R}_+ \end{array} \right. \quad (6)$$

$$\left\{ \begin{array}{l} -\eta \leq \theta \leq \eta, \lambda \leq 1 \end{array} \right. \quad (7)$$

$$\text{s. t. } \left\{ \begin{array}{l} -\frac{2}{3}\theta \leq \frac{2}{3}\theta + \pi s \leq \frac{2}{3}\theta \end{array} \right. \quad (8)$$

$$\left\{ \begin{array}{l} \lambda \leq \frac{27}{4} [\pi(R_U - s^T m)]^{\frac{2}{3}} \end{array} \right. \quad (9)$$

式中: $s = [-1, 1]^T$, λ, θ, η 和 π 为辅助变量。

然而,可以发现约束条件式(9)实际上是凸的。通过引入几个辅助变量 y, t_1, t_2 ,可以将它重新定义为线性不等式和二阶锥:

$$y = 4\lambda/27$$

$$t_1 \leq \pi(R_U - s^T m)$$

$$\left\| t_2 \frac{y-1}{2} \right\|_2 \leq \frac{y+1}{2} \quad (10)$$

$$\left\| y \frac{t_1 - t_2}{2} \right\|_2 \leq \frac{t_1 + t_2}{2}$$

为了证明它们的等价性,展开两个二阶锥,可以得到 $t_2^2 \leq y, y^2 \leq t_1 t_2$; 消除 t_2 得到 $y^3 \leq t_1^2$, 因此 $\lambda \leq \frac{27}{4} [\pi(R_U - s^T m)]^{\frac{2}{3}}$ 。

最后,将基于矩模糊集 S_1 的概率不等式(3)转化为二阶锥规划,即可以进行有效的求解。

1.3 基于散度的方法

基于矩的方法有两个输入参数:平均值和平均绝对偏差,可以从非常有限的的数据或粗略地猜测中恢复出来。随着数据可用性的提高,虽然基于矩的模型仍然适用,但由于历史数据所揭示的分布信息没有得到充分利用,因此可能不再是一个很好的选择。为了充分利用数据,本文考虑了一个由 N 个独立样本 \hat{w}_i^0 组成的经验分布 $f_0 = \frac{1}{N} \sum_{i=1}^N \delta_{\hat{w}_i^0}$, 每个样本的概率为 $1/N$ 。 $\delta_{\hat{w}_i^0}$ 表示 \hat{w}_i^0 处的 Dirac 分布集中单位质量。

然而, f_0 通常是不准确的,所以本文使用一个模糊集,其中包含所有与经验分布 f_0 足够接近的偏微分方程。为了量化两个偏微分方程之间的距离,本文采用 Wasserstein 度量,定义为:

$$D_W(f, f_0) = \inf_{\Pi} \int \|\mathbf{w} - \mathbf{w}^0\|_p \Pi(d\mathbf{w}, d\mathbf{w}^0)$$

式中: Π 是 \mathbf{w} 和 \mathbf{w}^0 的联合分布, 其边缘为 \mathbf{Q} 和 \mathbf{Q}_0 。
 $\|\cdot\|_p$ 是 \mathbf{R}^2 上的 p 范数。

对于两个离散分布, Wasserstein 度量表示为:

$$D_W(f, f_0) = \inf_{\pi} \sum_{i \geq 0} \sum_j \pi_{ij} \|\mathbf{w}_j - \mathbf{w}_i^0\|_p$$

式中: $\sum_j \pi_{ij} = p_i^0, \forall i; \sum_i \pi_{ij} = p_j, \forall j; p_i^0$ 和 p_j 表示典型场景 \mathbf{w}_i^0 和 \mathbf{w}_j 的概率。

使用 Wasserstein 距离度量, 模糊集可以构造为:

$$S_2 = \{f(\mathbf{w}) \mid D_W(f, f_0) \leq d_w\} \quad (11)$$

式中: d_w 是确定模糊集大小的常数。当 $d_w > 0$ 时, 模糊集中存在无穷多个偏微分方程; 当 d_w 接近 0 时, 模糊集收敛到经验分布 f_0 。根据文献[13], d_w 表达式为:

$$d_w = -\log(\alpha^*)/N \quad (12)$$

$f \in S_2$ 的置信水平至少为 $1 - \alpha^*$ 。显然, 当 N 增大时, d_w 减小, 这意味着数据越多, 经验分布 f_0 越准确。

Kullback-Leibler (KL) 散度是另一个著名的概率分布距离度量。对于这两种度量方法, 模糊集中的距离阈值在实际应用中都是一个关键参数。对于 Wasserstein 度量, d_w 可以通过式 (12) 选择, 而对于 KL 散度, 这样的参数选择有点困难。此外, 基于 Wasserstein 度量的模糊集可以提供令人满意的样本外性能保证。所以本文选择 Wasserstein 度量进行研究。

将 S_2 代入式 (3), 得到的概率不等式可以重新表示为以下形式:

$$\inf 1 - \frac{1}{N} \sum_{n=1}^N \beta_n + \gamma d_w \quad (13)$$

$$\text{s. t. } \begin{cases} \beta \in \mathbf{R}^N, \gamma \in \mathbf{R}_+, \tau \in \mathbf{R}_+^N & (14) \\ \beta_n \leq 1, \forall n = 1, \dots, N & (15) \\ \beta_n + \tau_n s w_n \leq \tau_n R_U, \forall n = 1, \dots, N & (16) \\ \|\tau_n s\|_q \leq \gamma, \forall n = 1, \dots, N & (17) \end{cases}$$

式中: $s = [-1, 1]^T$, β, γ 和 τ 为辅助变量, $\|\cdot\|_q$ 是 $\|\cdot\|_p$ 的对偶范数, p 和 q 满足 $p^{-1} + q^{-1} = 1$ 。

除了范数约束式 (17), 目标函数式 (13) 和约束式 (14) - 式 (16) 都是线性的。然而, 可以发现当 $p = 1$ 或 $p = \infty$ 时, 式 (17) 为线性约束, 当 $p = 2$ 时, 式 (17) 为二阶锥约束。本文选择 $p = \infty, q = 1$, 且式 (17) 表示为以下线性形式:

$$2\tau_n \leq \gamma, \forall n = 1, \dots, N \quad (18)$$

2 算例分析

这里将本文模型与高斯混合模型 (Gaussian mix-

ture model, GMM) 进行比较, 并用华北地区风电场的实际数据进行检验, 所用数据集为 2006 年 1 月 1 日至 2015 年 12 月 31 日的小时点预测和观测输出。为了检验 200 MW 斜坡事件的可能性, 选择两个连续的小时, 其中风电预测分别在 [495 MW, 505 MW] 和 [695 MW, 705 MW] 之间。从数据集中恢复 1 083 个数据对, 在算例分析时, 只估计了向上斜坡事件的概率, 向下斜坡可以用同样的方法处理。在 MATLAB R2018a 中用 YALMIP 编制了线性程序和二阶圆锥程序, 并用 CPLEX 12.8 进行了求解。

为了便于比较, 采用 GMM 进行斜坡概率估计。GMM 是多种高斯分布的混合体, 可以描述服从任意分布的不确定性。本文 GMM 分布中包含了三种高斯分布, 其中, 基于 GMM 的模型、基于矩的模型和基于散度的模型计算得到的风电斜坡概率分别称为 GMM-WRP、Moment-WRP 和 Div-WRP, 根据历史数据观测到的风力发电斜坡概率表示为 O-WRP。表 1 和图 2 比较了不同斜坡阈值 R_U 的结果。可以观察到 GMM-WRP 和 Div-WRP 与 O-WRP 非常接近, 而 Moment-WRP 总是大于它们。这是因为基于 GMM 的模型和基于散度的模型充分利用了历史数据的离散性, 而基于矩的模型只考虑了两个分布参数, 忽略了更多有用的信息。然而, 考虑到预测误差的单峰性, 当 $R_U > 280$ MW 时, Moment-WRP 随斜坡阈值 R_U 的增大而迅速减小, 与 GMM-WRP 和 Div-WRP 相当。表 1 中, 当 $R_U = 300$ MW 和 400 MW 时, GMM-WRP 小于 O-WRP, 而 Div-WRP 总是大于 O-WRP。这表明, 与基于 GMM 的模型相比, 本文提出的基于散度的模型可以提供更保守、更可靠的估计, 以保证电力系统的安全运行。此外, 表 1 列出了用给定阈值估计斜坡概率的平均计算时间, 可以发现, 基于 GMM 的模型比所提出的数据驱动模型花费的时间要长得多, 这是因为其计算包括两个步骤: 参数估计和基于蒙特卡罗的概率计算。

表 1 不同模型估计的斜坡概率

R_U (MW)	O-WRP	GMM-WRP	Moment-WRP	Div-WRP
200	46.81%	49.42%	100%	47.41%
250	32.59%	34.93%	48.37%	33.33%
300	23.08%	22.53%	23.94%	23.78%
400	7.66%	7.15%	11.91%	7.97%
500	1.11%	1.53%	7.93%	1.26%
600	0	0.21%	5.94%	0.19%
时间/s	-	29.68	0.32	2.13

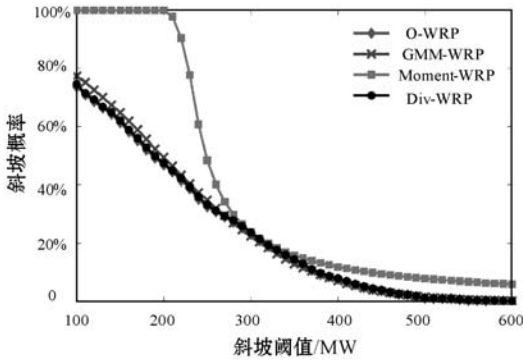
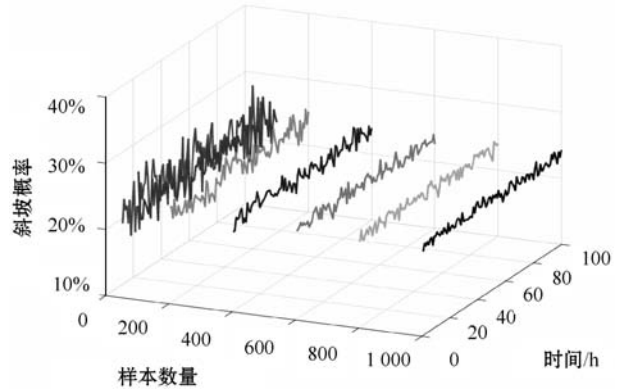



图2 不同模型计算的斜坡概率

在数据驱动方法中,历史样本数是影响估计结果的一个关键因素。为了研究其影响,本文首先使用文献[14]中的场景生成方法,基于上述1 083个数据对生成10 000个风电场景。随后,从10 000个场景中随机选取一组具有给定元素数的样本,测试三个模型的性能,此过程重复100次。 $R_U = 300$ MW的结果如图3所示。随着抽样数据的增加,三种模型的波动率均减小,说明样本数对概率估计的稳定性有显著影响,而且矩模型的波动率明显小于GMM模型和散度模型的波动率,因为其使用的历史数据信息最少,所以几乎不受样本数变化的影响。




(b) 基于矩的模型



(c) 基于散度的模型

图3 不同样本数的斜坡概率($R_U = 300$ MW)



(a) 基于GMM的模型

表2给出了不同 R_U 值和采样数据 N_s 情况下估计斜坡概率的统计信息。采样数据越多时,斜坡概率的标准差和其限值之间的差异会显著减小。当 $N_s \leq 200$ 时,GMM-WRP和Div-WRP比Moment-WRP更敏感,因为这两个模型中使用的色散信息必须基于一定数量的样本,而矩模型对中等数据的敏感度较低。当 $N_s \geq 400$ 时,GMM-WRP和Div-WRP在估计精度上要明显优于Moment-WRP。然而,GMM-WRP估计可以是乐观的,也可以是悲观的,而Div-WRP总是保守的,这可以从 $R_U = 300$ MW和400 MW时的平均值观察到。

表2 不同 N_s 和 R_U 值下斜坡概率的统计信息

R_U /MW	N_s	平均值			标准差		
		GMM-WRP	Moment-WRP	Div-WRP	GMM-WRP	Moment-WRP	Div-WRP
200	50	47.25%	100%	49.54%	6.18%	0%	7.09%
	100	47.36%	100%	48.37%	4.60%	0%	4.80%
	200	47.69%	100%	48.88%	3.65%	0%	3.86%
	400	48.08%	100%	48.64%	2.41%	0%	2.40%
	600	48.33%	100%	48.33%	2.04%	0%	1.88%
	800	48.33%	100%	48.22%	1.89%	0%	1.75%
	1 000	48.23%	100%	48.00%	1.55%	0%	1.52%
250	50	32.98%	47.77%	36.21%	5.48%	5.15%	6.03%
	100	33.85%	48.21%	36.28%	4.18%	3.98%	4.60%
	200	34.64%	47.55%	36.22%	3.07%	2.67%	3.61%

续表 2

R_U/MW	N_S	平均值			标准差		
		GMM-WRP	Moment-WRP	Div-WRP	GMM-WRP	Moment-WRP	Div-WRP
250	400	34.55%	47.80%	35.78%	2.17%	1.98%	2.28%
	600	34.78%	47.78%	35.87%	1.81%	1.66%	1.90%
	800	34.91%	48.06%	35.86%	1.64%	1.41%	1.64%
	1 000	35.15%	47.89%	35.67%	1.48%	1.16%	1.38%
300	50	22.09%	23.31%	25.14%	5.47%	2.60%	6.23%
	100	22.04%	23.69%	24.19%	3.36%	1.88%	4.23%
	200	22.22%	23.56%	24.49%	3.00%	1.27%	3.43%
	400	22.65%	23.66%	24.38%	2.00%	0.92%	2.06%
	600	22.58%	23.67%	24.16%	1.64%	0.76%	1.79%
	800	22.62%	23.72%	24.10%	1.47%	0.68%	1.52%
	1 000	22.23%	23.62%	23.81%	1.34%	0.58%	1.25%
400	50	6.43%	11.89%	8.47%	3.12%	1.41%	3.77%
	100	6.25%	11.80%	7.23%	1.64%	0.83%	2.11%
	200	6.58%	11.84%	7.65%	1.46%	0.64%	1.91%
	400	6.58%	11.75%	7.40%	1.04%	0.45%	1.36%
	600	6.75%	11.85%	7.67%	0.86%	0.37%	1.00%
	800	6.60%	11.77%	7.32%	0.76%	0.30%	0.92%
	1 000	6.55%	11.79%	7.30%	0.67%	0.27%	0.82%
500	50	1.32%	7.91%	1.70%	0.95%	0.82%	1.71%
	100	1.39%	7.84%	1.77%	0.66%	0.65%	1.19%
	200	1.20%	7.84%	1.42%	0.51%	0.52%	0.80%
	400	1.28%	7.80%	1.49%	0.36%	0.32%	0.54%
	600	1.23%	7.86%	1.37%	0.28%	0.26%	0.44%
	800	1.21%	7.87%	1.38%	0.29%	0.20%	0.43%
	1 000	1.15%	7.84%	1.35%	0.20%	0.18%	0.28%
600	50	0.18%	5.79%	0.25%	0.21%	0.70%	0.37%
	100	0.16%	5.87%	0.17%	0.15%	0.44%	0.27%
	200	0.15%	5.87%	0.19%	0.10%	0.34%	0.27%
	400	0.14%	5.85%	0.13%	0.07%	0.23%	0.15%
	600	0.13%	5.87%	0.13%	0.06%	0.18%	0.12%
	800	0.12%	5.88%	0.10%	0.04%	0.14%	0.10%
	1 000	0.12%	5.86%	0.14%	0.04%	0.13%	0.10%
R_U/MW	N_S	最大值			最小差		
		GMM-WRP	Moment-WRP	Div-WRP	GMM-WRP	Moment-WRP	Div-WRP
200	50	63.67%	100%	65.09%	33.32%	100%	31.50%
	100	58.95%	100%	59.75%	37.34%	100%	37.08%
	200	55.95%	100%	56.57%	36.86%	100%	38.81%
	400	53.69%	100%	55.17%	42.54%	100%	40.75%
	600	53.95%	100%	52.83%	43.80%	100%	43.21%
	800	53.84%	100%	52.96%	43.85%	100%	43.94%
	1 000	51.68%	100%	51.50%	45.06%	100%	44.60%

续表 2

R_U/MW	N_s	最大值			最小差		
		GMM-WRP	Moment-WRP	Div-WRP	GMM-WRP	Moment-WRP	Div-WRP
250	50	46.06%	61.56%	52.50%	21.70%	37.46%	19.33%
	100	47.83%	61.22%	48.50%	21.59%	37.56%	23.86%
	200	45.21%	53.85%	48.67%	27.49%	39.96%	27.87%
	400	39.79%	53.21%	41.58%	29.03%	42.89%	29.75%
	600	39.34%	52.45%	41.33%	30.34%	44.01%	32.17%
	800	39.04%	51.69%	40.29%	30.17%	44.80%	32.37%
	1 000	39.53%	51.23%	38.35%	31.67%	43.99%	32.62%
300	50	33.93%	28.93%	39.25%	11.20%	17.98%	12.48%
	100	28.81%	29.25%	33.08%	13.36%	18.84%	14.26%
	200	29.37%	26.37%	32.33%	15.56%	20.91%	16.83%
	400	27.90%	25.77%	29.67%	15.95%	21.51%	19.50%
	600	26.40%	25.74%	27.50%	17.07%	21.59%	18.43%
	800	27.91%	25.05%	28.09%	18.33%	21.89%	20.47%
	1 000	25.41%	24.94%	26.43%	18.18%	22.27%	20.17%
400	50	13.98%	16.85%	18.21%	0.28%	9.32%	0.48%
	100	11.55%	13.92%	12.50%	2.25%	9.29%	2.46%
	200	10.22%	13.27%	13.21%	3.97%	10.41%	3.93%
	400	9.20%	13.07%	11.36%	3.91%	10.83%	4.19%
	600	8.65%	13.06%	10.19%	5.13%	10.95%	5.89%
	800	8.68%	12.50%	10.04%	5.00%	10.99%	5.42%
	1 000	8.13%	12.53%	9.50%	4.53%	11.04%	5.30%
500	50	4.24%	9.87%	8.00%	0.02%	5.82%	0.09%
	100	3.10%	9.26%	6.12%	0.15%	6.49%	0.12%
	200	2.57%	9.44%	3.60%	0.23%	6.66%	0.18%
	400	2.65%	8.46%	3.03%	0.62%	7.01%	0.31%
	600	1.95%	8.52%	2.71%	0.64%	7.31%	0.57%
	800	2.38%	8.57%	2.55%	0.67%	7.44%	0.53%
	1 000	1.71%	8.22%	2.00%	0.51%	7.41%	0.64%
600	50	0.78%	7.94%	2.46%	0%	4.26%	0.03%
	100	0.99%	7.25%	1.12%	0%	4.72%	0.04%
	200	0.49%	6.78%	1.05%	0.01%	5.19%	0.03%
	400	0.34%	6.32%	0.61%	0.03%	5.31%	0.02%
	600	0.35%	6.28%	0.50%	0.04%	5.42%	0.03%
	800	0.27%	6.20%	0.44%	0.05%	5.51%	0.02%
	1 000	0.29%	6.10%	0.50%	0.06%	5.58%	0.03%

综上所述,对于系统调度员来讲,当只有有限的历史数据时,建议使用基于矩的模型。即使在完全没有数据的情况下,如果对平均值和平均绝对偏差提供适当的猜测,也可以应用该模型。相反,在数据量较大的情况下,由于散度模型可以有更精确的估计结果,且具有分布鲁棒性保证,因此可以使用散度模型来限制斜坡事件的概率上限。

3 结 语

本文提出了一种基于数据驱动概率的不等式模型,在给定斜坡阈值下,用于估计发生风电斜坡事件的概率上限。利用风电时间信息和风电出力的单峰性构造了模糊集,在构造基于散度的模糊集时,使用了

Wasserstein 标准度量两种概率分布之间的差异。在此基础上建立了不确定量化模型,其优势在于不需依赖不确定因素的精确分布,并且使用了计算上可处理的凸优化。最后,表3中给出了本文讨论模型的性能比较和总体评价,作为应用选择的参考。

表3 不同模型的性能

指标	基于 GMM 模型	基于 Moment 模型	基于 Div 模型
数据需求	大量	少量	中等
准确性	较准确	较保守	略保守
鲁棒性	无保证	稳定	稳定
计算压力	高	非常低	低

参 考 文 献

- [1] Kamath C. Understanding wind ramp events through analysis of historical data[C]//IEEE PES T&D 2010. IEEE, 2010.
- [2] 刘红柳,杨茂. 基于小波变换和支持向量机的风电功率爬坡事件识别与预测[J]. 东北电力大学学报,2016(6): 30-35.
- [3] 戚永志,刘玉田. 基于竞争博弈的风电爬坡协同控制策略[J]. 中国电机工程学报,2014,34(25):4341-4349.
- [4] Cutler N, Kay M, Jacka K, et al. Detecting, categorizing and forecasting large ramps in wind farm power output using meteorological observations and WPPT[J]. Wind Energy, 2007,10(5):453-470.
- [5] 崔明建,孙元章,柯德平. 基于原子稀疏分解和BP神经网络的风电功率爬坡事件预测[J]. 电力系统自动化,2014,38(12):6-11.
- [6] 欧阳庭辉,查晓明,秦亮,等. 风电功率爬坡事件预测时间窗口的选取[J]. 电网技术,2015,39(2):414-419.
- [7] Zhang J, Florita A, Hodge B M, et al. A suite of metrics for assessing the performance of solar power forecasting[J]. Solar Energy,2015,111:157-175.
- [8] 艾小猛,韩杏宁,文劲宇. 考虑风电爬坡事件的鲁棒机组组合[J]. 电工技术学报,2015,30(24):188-195.
- [9] Greaves B, Collins J, Parkes J, et al. Temporal forecast uncertainty for ramp events[J]. Wind Engineering,2009,33(4):309-319.
- [10] Li Z, Ye L, Zhao Y, et al. Short-term wind power prediction based on extreme learning machine with error correction[J]. Protection & Control of Modern Power Systems, 2016,1(1): 2367-2617.
- [11] Pinson P, Kariniotakis G. Conditional prediction intervals of wind power generation[J]. IEEE Transactions on Power Systems,2010,25(4):1845-1856.
- [12] Hanasusanto G A, Roitch V, Kuhn D. A distributionally robust perspective on uncertainty quantification and chance constrained programming[J]. Mathematical Programming, 2015,151(1):35-62.
- [13] Fournier N, Guillin A. On the rate of convergence in Wasserstein distance of the empirical measure[J]. Probability Theory and Related Fields, 2015,162(3/4):707-738.
- [14] Pinson P, Girard R. Evaluating the quality of scenarios of short-term wind power generation[J]. Applied Energy, 2012,96:12-20.

(上接第50页)

- [11] Ma J, Gao W, Mitra P, et al. Detecting rumors from microblogs with recurrent neural networks[C]//Twenty-Fifth International Joint Conference on Artificial Intelligence,2016: 3818-3824.
- [12] Guo H, Cao J, Zhang Y, et al. Rumor detection with hierarchical social attention network[C]//27th ACM International Conference on Information and Knowledge Management, 2018:943-951.
- [13] Yu F, Liu Q, Wu S, et al. A convolutional approach for misinformation identification[C]//Twenty-Sixth International Joint Conference on Artificial Intelligence,2017.
- [14] 潘浩彬. 融合领域知识的深度谣言检测方法研究[D]. 北京:中国科学院大学,2019.
- [15] Wu K, Yang S, Zhu K Q. False rumors detection on sina weibo by propagation structures[C]//2015 IEEE 31st International Conference on Data Engineering,2015:651-662.
- [16] Ruchansky N, Seo S, Liu Y. CSI: A hybrid deep model for fake news detection[C]//2017 ACM on Conference on Information and Knowledge Management,2017:797-806.
- [17] Cao J, Guo J, Li X, et al. Automatic rumor detection on microblogs: A survey[EB]. arXiv:1807.03505,2018.
- [18] Kim Y. Convolutional neural networks for sentence classification[EB]. arXiv:1408.5882,2018.
- [19] Mikolov T, Karafiát M, Burget L, et al. Recurrent neural network based language model[C]//Eleventh Annual Conference of the International Speech Communication Association,2010.
- [20] Hochreiter S, Schmidhuber J. Long short-term memory[J]. Neural Computation,1997,9(8):1735-1780.
- [21] Cho K, Merriënboer B V, Gulcehre C, et al. Learning phrase representations using RNN encoder-decoder for statistical machine translation[EB]. arXiv:1406.1078,2014.
- [22] Kingma D P, Ba J. Adam: A method for stochastic optimization[EB]. arXiv:1412.6980,2014.