

# 基于切片采样的风力发电并网系统 概率潮流计算

张晓英<sup>1</sup> 王 琨<sup>1</sup> 张蜡宝<sup>2</sup>

(1. 兰州理工大学电气工程与信息工程学院 兰州 730050

2. 南京大学电子科学与工程学院 南京 210093)

**摘要** 在基于马尔科夫链蒙特卡洛 (MCMC) 模拟法的概率潮流计算方法中, 被广泛应用的 Gibbs 采样算法需要进行大量复杂的迭代运算才能得到较精确的计算结果。针对该算法的缺陷, 提出基于切片采样 (slice sampling) 算法的 MCMC 方法, 并应用于风力发电并网系统概率潮流计算中。首先, 采用加权高斯混合分布 (WGMD) 对风电场出力进行建模; 然后, 通过切片采样算法对风电场出力的概率分布进行采样, 从而构建出风电场出力的样本空间; 最后, 对样本空间中的每组采样点进行潮流计算, 并在含有风电模型的 IEEE 39 节点系统中与 Gibbs 采样算法得到的结果进行比较。结果表明: 切片采样算法能够显著提高传统 MCMC 方法的计算准确度; 同时, 在与 Gibbs 算法采样迭代次数相同的情况下, 切片采样算法所生成的马尔科夫链可以更快、更稳定地收敛于平稳分布。

**关键词:** 风电并网 概率潮流 切片采样 Gibbs 采样 马尔科夫链蒙特卡洛模拟法

**中图分类号:** TM712

## Probabilistic Load Flow Calculation Based on Slice Sampling for Wind Farms Integration System

Zhang Xiaoying<sup>1</sup> Wang Kun<sup>1</sup> Zhang Labao<sup>2</sup>

(1. College of Electrical and Information Engineering Lanzhou University of Technology

Lanzhou 730050 China

2. School of Electronic Science and Engineering Nanjing University Nanjing 210093 China)

**Abstract** Gibbs sampling algorithm that is widely used in Markov Chain Monte Carlo (MCMC) simulation method suffers from complicated sampling iterations when accurate results from probabilistic load flow is required. According to the defect, an improved MCMC method based on Slice sampling is proposed in this paper and is integrated into probabilistic load flow algorithm for wind farms integration system. The probabilistic model of wind farm outputs is firstly constructed by weighted Gaussian mixture distribution (WGMD). Then, the sample space of wind farm outputs is obtained by Slice sampling from the WGMD of wind farm outputs. Finally, the samples from the sample space of wind farm outputs are calculated by load flow and the results of these two sampling methods are compared in IEEE 39-bus system. It is shown that the proposed method can distinctly improve the calculation accuracy of MCMC method. Additionally, the Markov Chain generated by Slice sampling can reach a stationary distribution more quickly and stably than Gibbs sampling with the same iterations.

**Keywords:** Wind farms integration, probabilistic load flow, slice sampling, Gibbs sampling, Markov Chain Monte Carlo simulation method

国家自然科学基金资助项目(51267012)。

收稿日期 2015-07-10 改稿日期 2015-12-08

## 0 引言

风力发电对环境的影响较小,同时发电成本不断下降,因此成为新能源发电中发展最快、最具有发展前景的一种发电方式。然而风能这种清洁能源具有显著的随机性、间歇性和不可调度性的缺点<sup>[1]</sup>。随着风电渗透率的提高,其对电力系统在安全性和稳定性方面的影响也越来越明显<sup>[2]</sup>。

为了全面分析风力发电并网对电力系统稳定性的影响,需要精确计算出系统潮流分布情况。而风能的不确定性决定了风电并网系统潮流分布的不确定性,因此概率统计法成为了分析此类系统的基本方法。20世纪70年代B. Borkowska首次提出概率潮流(Probabilistic Load Flow, PLF)计算的概念<sup>[3]</sup>,此后该计算方法在包括电压稳定性分析、可靠性评估、网损分析等在内的电力系统分析领域得到广泛的应用。概率潮流算法的核心思想是:将输入随机变量的概率统计特性引入潮流计算当中,从而求得电网潮流指标的概率统计特性,如期望、方差、概率密度函数(Probability Density Function, PDF)、累计分布函数(Cumulative Distribution Function, CDF)等。

由于概率潮流能够更有效地模拟电力系统实际运行情况,因此经过多年研究,国内外学者提出了多种类型的概率潮流计算方法。其中,解析法<sup>[3-5]</sup>通过简化的卷积计算能够达到很快的计算速度,但计算准确度不高,且各输入变量之间相互独立的假设与实际电力系统运行不相符。点估计法<sup>[6-7]</sup>通过运行两倍随机参数个数的潮流程序计算所得参数的各阶矩,与解析法相比计算时间有所增加,虽然相应的计算准确度略有提高,但采样值不具备普遍性,同样无法满足计算准确度要求。

蒙特卡洛模拟法(Monte Carlo Simulation, MCS)<sup>[8-10]</sup>在采样规模足够大的情况下,计算准确度较高,但其计算量过大、耗时过长。因此,这种方法大多作为验证其他方法准确程度的标准。针对MCS方法的不足,一些学者将随机过程中的马尔科夫过程引入到蒙特卡洛模拟中,形成了马尔科夫链蒙特卡洛(Markov Chain Monte Carlo, MCMC)模拟法<sup>[11-12]</sup>,其基本思想是:通过重复抽样,建立一个平稳分布与系统先验概率分布相同的马尔科夫链,从而得到系统的状态样本。被广泛用于构建马尔科夫链的Metropolis-Hastings算法和Gibbs算法存在着不可忽视的缺点:实现Metropolis-Hastings采样算法需要找到一种合适的建议分布;与此类似的是,使用Gibbs采样算法时必须构造一种从

非标准单变量分布抽样的算法以实现有效抽样<sup>[13,14]</sup>;由于易受初始值的影响,Gibbs采样算法稳定性较低,且需要进行大量迭代运算才能达到收敛。这些缺陷限制了MCMC方法在电力系统中的应用。

本文将切片采样(slice sampling)算法<sup>[14]</sup>引入到风力发电并网系统概率潮流计算中。与Gibbs采样算法相比,切片采样算法改善了采样值在随机变量分布中的覆盖程度、提高了采样效率。在对IEEE 39节点系统进行风电并网改造后,分别采用Gibbs采样算法和切片采样算法进行概率潮流计算,结果证明了所提算法的高效性和准确性。

## 1 风电场概率模型的建立

在风电并网系统概率潮流计算中,风电场概率模型的建立方法主要有两种:一种是基于风速概率密度函数的建模方法<sup>[15]</sup>;另一种是基于风电场有功出力时间随机序列的建模方法<sup>[16]</sup>。根据风电场实测风电出力数据分析得出,在不同时间尺度下,风电出力波动较大、变化复杂,呈较强的非线性。风速概率密度函数建模法需要通过满足特定概率分布的风速进行变换得到风电场有功出力,在对大规模风电并网系统潮流分析时,其拟合误差无法满足潮流计算的准确度要求。对于时间随机序列的建模方法来说,虽然该方法可以比较精确地模拟出风电场在任何时间段的功率波动变化,但是要依靠大量的风电场实测数据,并且在生成概率转移核矩阵时需要进行大量计算,因此其适用范围受到了局限。

加权高斯混合分布(Weighted Gaussian Mixture Distribution, WGMD)通过多个高斯分布的加权组合可以平滑地近似任意复杂形态的数据分布。采用该分布构建风电场有功出力的概率模型时,由于直接采用了风电场有功出力的实测数据,可以避免由风速变换风功率时带来的误差。同时,在生成风功率时间序列时不需要构建概率转移核矩阵,可以提高建模效率。因此,该方法更适合用于描述风电出力的随机性和波动性等非线性分布特性。蔺红等人采用加权高斯混合分布概率模型对新疆某地区风电场的出力进行研究,其结果也证实了加权高斯混合概率模型在模拟风电出力方面的准确性和有效性<sup>[17]</sup>。综上所述,本文采用基于加权高斯混合分布的风电场概率建模法进行概率潮流计算。

采用加权高斯混合分布来表示风电场出力的概率函数为

$$f(x) = \sum_{m=1}^M \alpha_m G_m(x|\theta_m) = \sum_{m=1}^M \alpha_m \frac{1}{\sqrt{2\pi}\sigma_m} e^{-\frac{(x-\mu_m)^2}{2\sigma_m^2}} \quad (1)$$

式中,  $\theta_m = \{\mu_m, \sigma_m^2, m = 1, 2, \dots, M\}$ ;  $\sum_{m=1}^M \alpha_m = 1$ ;  $\alpha_m \geq 0$ ;  $\alpha_m, \mu_m, \sigma_m^2$  分别为高斯混合模型  $m$  分量的权重和该权重高斯分布  $G_m(\cdot)$  的均值、方差, 需要通过观察数据进行计算。本文采用极大似然估计(Expectation Maximization, EM) 算法<sup>[17, 18]</sup>求解风电场出力概率函数中的未知参数。EM 算法是 A. P. Dempster 等在研究不完全数据的最大似然估计时提出的一种迭代算法, 因其算法复杂度较低, 在信号处理领域得到了广泛的应用<sup>[19]</sup>。

给定风电场出力实测数据  $X = \{x_1, x_2, \dots, x_N\}$ , 其概率模型的似然函数为

$$L(\theta|X) = \prod_{n=1}^N f(x_n) \quad n = 1, 2, \dots, N \quad (2)$$

式中,  $\theta = \{\theta_1, \theta_2, \dots, \theta_N\}$ 。对式(2)取对数得

$$l(\theta) = \ln[L(\theta|X)] = \sum_{n=1}^N \ln \sum_{m=1}^M \alpha_m G_m(x_n|\theta_m) \quad (3)$$

EM 算法进行参数估计主要由两步完成, 即

E 步: 计算对数似然函数的条件期望, 即

$$Q(\theta|\theta^{(p)}) = E[l(\theta)|\theta^{(p)}] \quad (4)$$

M 步: 寻找  $\theta^{(p+1)}$ , 使得

$$\theta^{(p+1)} = \operatorname{argmax}_{\theta} Q(\theta|\theta^{(p)}) \quad (5)$$

当考虑约束条件  $\sum_{m=1}^M \alpha_m = 1$  且  $\alpha_m \geq 0$  时, EM 算法求解风电场出力概率函数中未知参数的迭代步骤如下:

- 1) 初始化迭代参数  $\theta^{(0)}$ 。
- 2) 迭代计算式(6)所示参数, 直到收敛。

$$\left\{ \begin{aligned} \alpha_m^{(p+1)} &= \frac{1}{N} \sum_{n=1}^N \omega_{nm} \\ \mu_m^{(p+1)} &= \frac{\sum_{n=1}^N \omega_{nm} \cdot x_n}{\sum_{n=1}^N \omega_{nm}} \\ [\sigma_m^{(p+1)}]^2 &= \frac{\sum_{n=1}^N \omega_{nm} \cdot (x_n - \mu_m^{(p+1)})^2}{\sum_{n=1}^N \omega_{nm}} \\ \omega_{nm} &= \frac{\alpha_m \cdot G_m(x_n|\theta_m^{(p)})}{\sum_{m=1}^M \alpha_m \cdot G_m(x_n|\theta_m^{(p)})} \end{aligned} \right. \quad (6)$$

## 2 切片采样算法

切片采样算法由 J. Besag 和 P. G. Green 在 1993 年首先引入主流统计学研究领域<sup>[20]</sup>。切片采样算法在采样过程中需要引入辅助变量, 当引入单辅助变量后, 其采样过程可以被看作是目标概率密度函数图像下的 Gibbs 采样算法。

假设从集合  $R^n$  中的一个概率分布抽取变量  $x$ , 其概率密度函数与某一个函数  $f(x)$  呈正比。这个思想可以通过引入一个辅助变量  $y$  同时定义一个  $x, y$  的联合分布函数来实现, 其中  $y$  在函数  $f(x)$  曲线下的区域为  $U = \{(x, y): 0 < y < f(x)\}$ 。由此,  $(x, y)$  的联合概率密度函数为

$$f(x, y) = \begin{cases} \frac{1}{Z} & 0 < y < f(x) \\ 0 & \text{其他} \end{cases} \quad (7)$$

式中,  $Z = \int f(x) dx$ 。  $x$  的边缘概率密度函数为

$$p(x) = \int_0^{f(x)} \left( \frac{1}{Z} \right) \cdot dy = \frac{f(x)}{Z} \quad (8)$$

要对  $x$  采样只需对  $(x, y)$  的联合分布采样后再消去  $y$  即可实现。然而想要从  $U$  均匀地产生相互独立的样本点是比较困难的, 因此需要定义一个收敛于这个均匀分布的马尔科夫链。本文产生样本点的可行性方法是用 Gibbs 采样法: 首先给定  $x$  对  $y$  的条件分布(在区间  $(0, f(x))$  上的均匀分布), 并给定  $y$  对  $x$  的条件分布(在区域  $S = \{x: y < f(x)\}$  上的均匀分布, 其中  $S$  被称为切片并由  $y$  来定义), 然后交替从这两个条件分布中抽样。根据文献[14]提出的方法, 在通常情况下新抽取的采样值  $x_1$  要替换初始采样值  $x_0$  要进行以下三个步骤: ①切片生成, 即在区间  $(0, f(x_0))$  上确定实数  $y$  用来生成切片  $S$ (切片  $S$  应包含初始采样值  $x_0$ ); ②区间确定, 即在  $x_0$  周围找到一个区间  $I = (L, R)$  并且要包含切片  $S$  的大部分区域; ③样本采样, 即从切片  $S$  和区间  $I$  的交集部分抽取新的采样点  $x_1$ 。

### 2.1 切片生成

由于切片  $S$  是由辅助变量  $y$  来定义的, 因此首先确定  $y$  的值, 并在马尔科夫链的每次迭代过程中都要对辅助变量  $y$  进行更新。在实际计算中, 为了避免浮点下溢, 应该通过计算  $g(x) = \log(f(x))$  来间接达到计算  $f(x)$  的目的。因此辅助变量可表示为

$$Z = g(x_0) - e \quad (9)$$

式中,  $e$  为期望是 1 的指数分布。切片  $S$  可以表示为

$$S = \{x: Z < g(x)\} = \{x: g(x_0) - e < g(x)\} \quad (10)$$

## 2.2 区间确定

在确定区间  $I$  时所遵循的原则是: 保证  $I$  覆盖切片  $S$  的大部分区间, 以便抽取新的采样点与当前采样点相比有较大差别。同时, 为了防止采样效率的降低,  $I$  的范围不能大于切片  $S$ 。对于区间  $I$  的选取, 最简单的方法是将切片  $S$  的范围设定成最小区间, 换句话说就是定义区间  $I$  的左边界  $L$  和右边界  $R$  满足

$$\begin{cases} L = \inf(S) \\ R = \sup(S) \end{cases} \quad (11)$$

式中,  $\inf$  为上确界;  $\sup$  为下确界。然而在实际应用中, 这种方法却很难实现, 其根本原因在于并不是所有的方程  $y = f(x)$  都能够通过数值解法得到答案。在大多数情况下, 切片  $S$  是由多个不相交的区间构成的, 而这些不相交的区间很难用这种方法确定下来。

针对这种情况, 文献[14]提出了 Stepping-out 算法, 该算法适用于任何连续分布函数并且可以弥补上述方法的缺陷。如图1所示, 根据初始值  $x_0$ , 定义  $w$  为切片标准估计宽度、 $m$  为限定切片宽度极限的整数 (切片宽度极限为  $mw$ )、 $y$  为限定切片区间的水平线。分别从满足区间为  $(0, 1)$  的均匀分布中抽取随机数  $U$  和  $V$ , 同时对区间  $I$  的边界  $L$  和  $R$  进行如下迭代计算:

1) 输入边界迭代初值  $L = x_0 - wU$ 、 $R = L + w$ , 同时初始化迭代变量  $j = \text{floor}(mV)$ 、 $k = (m - 1) - j$ , 其中  $\text{floor}(\cdot)$  表示向下取整计算。

2) 判断  $j > 0$  和  $y < f(L)$  是否同时成立, 如果成立, 则更新左边界  $L = L - w$ 、 $j = j - 1$ ; 否则, 跳转到下一步。

3) 判断  $k > 0$  和  $y < f(R)$  是否同时成立, 如果成立, 则更新右边界  $R = R + w$ 、 $k = k - 1$ ; 否则, 结束迭代。




图1 Stepping-out 算法示意图

Fig. 1 Stepping-out algorithm

## 2.3 样本采样

当区间  $I$  被确定后, 则需用 Shrinkage 算法<sup>[14]</sup>来寻

找下一个采样点  $x_1$ 。

如图2所示, Shrinkage 算法的核心思想是: 如果寻找到的下一个采样点  $x_1$  在区间  $I$  所包含的切片上则保留; 否则以该点作为区间  $I$  的一个边界, 然后在更新后的区间  $I$  上继续寻找采样点  $x_1$  直到其落在区间  $I$  所包含的切片上为止。样本采样流程如下:

1) 令  $\bar{L} = L$ ,  $\bar{R} = R$ 。

2) 从满足区间为  $(0, 1)$  的均匀分布中抽取随机数  $U$ 。

3) 生成采样点  $x_1 = \bar{L} + U(\bar{R} - \bar{L})$ 。

4) 如果  $y < f(x_1)$  成立, 则  $x_1$  确认为新的采样点, 否则做出如下判断: 如果  $x_1 < x_0$ , 则区间  $I$  的左边界更新为  $\bar{L} = x_1$ ; 如果  $x_1 \geq x_0$ , 则区间  $I$  的右边界更新为  $\bar{R} = x_1$ 。然后返回步骤2) 继续寻找新的采样点。



图2 Shrinkage 算法示意图

Fig. 2 Shrinkage algorithm

## 3 基于切片采样的风电并网系统概率潮流计算流程

将本文提出的基于切片采样算法的改进 MCMC 方法应用于风电并网系统概率潮流计算当中。计算流程如下:

1) 建立风电场概率模型。文献[17]已经验证一维二分量加权高斯混合模型可以比较准确模拟出单个风电场有功出力的概率分布。因此, 用一维二分量加权高斯混合模型表示风电场有功出力的概率分布为

$$f_{\text{wind}}(x) = \alpha_1 \frac{1}{\sqrt{2\pi}\sigma_1} e^{-\frac{(x-\mu_1)^2}{2\sigma_1^2}} + \alpha_2 \frac{1}{\sqrt{2\pi}\sigma_2} e^{-\frac{(x-\mu_2)^2}{2\sigma_2^2}} \quad (12)$$

将风电场有功出力实测数据作为观察数据  $X = \{x_1, x_2, \dots, x_M\}$  代入 EM 算法迭代公式, 计算出风电场有功出力概率函数中的未知参数  $\alpha_m$ 、 $\mu_m$  和  $\sigma_m^2$ ,  $m = 1, 2$ 。

2) 样本生成。假设采样规模为  $N$ , 采用切片采样算法对风电场出力概率模型  $f_{\text{wind}}(x)$  和服从正态分布的负荷模型  $f_{\text{load}}(x)$  进行采样得到各变量的马尔科夫链  $[P_{\text{wind}}, P_{\text{load}}, Q_{\text{load}}]$ 。假设风力发电机组采用恒功率因数控制 ( $\cos\varphi = 0.9$ ), 则

$$Q_{\text{wind}} = P_{\text{wind}} \cdot \tan\varphi \quad (13)$$

由式(13)即可求出风电场无功功率的马尔科夫链  $Q_{\text{wind}}$ , 并由此构建出概率潮流计算所需的各种输入随

机变量的样本空间。

3) 概率潮流计算。假设风电场并网节点为 PQ 节点, 把样本空间  $[P_{\text{wind}} \ Q_{\text{wind}} \ P_{\text{load}} \ Q_{\text{load}}]$  中各组样本值依次代入牛顿拉夫逊潮流计算式中求出各节点和支路的潮流样本。

4) 并网系统概率评估。利用概率统计方法得出所需输出变量的随机特性和概率统计指标。

## 4 算例分析

本文以 IEEE 39 节点系统为算例, 比较 Gibbs 采样算法和切片采样算法。概率潮流计算基于 Matlab 的 Matpower 5.0b1 电力系统计算工具包。在 IEEE 39 节点系统的 30 节点和 37 节点分别接入风电场来替换节点原有的常规发电机组。风电场出力的历史数据来源于德国某电力公司控制区域内风电场 15 min 级平均功率序列<sup>[21]</sup>。服从正态分布的节点功率随机变量参数见表 1。

表 1 概率负荷的参数

Tab. 1 Parameters of probabilistic load

节点	有功功率		无功功率	
	均值( pu)	标准差( %)	均值( pu)	标准差( %)
3	3.22	5.4	0.02	5.4
18	1.58	7.2	0.30	7.2
25	2.24	4.6	0.47	4.3
26	1.39	6.7	0.17	6.7
39	11.04	1.1	2.50	1.2

### 4.1 算法的收敛速度比较

根据 MCMC 理论, 在经过  $N$  次采样迭代后舍去前  $M$  次采样值(也称为“退火”)得到的马尔科夫链收敛于平稳分布。目前有很多可以验证 MCMC 算法是否收敛的方法。本文所用 MCMC 收敛性判定方法为 Gelman-Rubin( G-R) 诊断方法<sup>[22 23]</sup>, 即

$$\begin{cases} \hat{R} = \frac{\hat{V}}{\text{WSS}} = \frac{N-1}{N} + \frac{\text{BSS}/N}{\text{WSS}} \cdot \frac{k+1}{k} \\ \hat{V} = \frac{N-1}{N} \cdot \text{WSS} + \frac{\text{BSS}}{N} \cdot \frac{k+1}{k} \\ \sqrt{\hat{R}_c} = \sqrt{\frac{d+3}{d+1}} \cdot \hat{R} \end{cases} \quad (14)$$

式中,  $\hat{R}$  为收缩因子  $R$  的估计量;  $\hat{V}$  为混合后验方差  $V$  的估计量;  $k$  为马尔科夫链数量;  $N$  为每条马尔科夫链的保留迭代次数;  $\text{BSS}/N$  为样本间方差;  $\text{WSS}$  为样本内方差;  $d$  为混合后验方差估计量  $\hat{V}$  的自由度;  $\hat{R}_c$

为估计值  $\hat{R}$  的修正量。G-R 诊断法利用同一随机变量生成的始于不同初始值的  $k$  条链来检验马尔科夫链是否收敛。当  $\sqrt{\hat{R}_c} \leq 1.1$ , 可认为马尔科夫链达到收敛。

应用本文所提方法对含有风电场概率模型的 IEEE 39 节点系统进行概率潮流计算。切片采样和 Gibbs 采样分别对每个风电场出力分布和负荷功率分布进行 5 000 次采样, 前 2 000 次用于“退火”。图 3 给出了概率潮流计算后 3 号节点电压幅值  $V$  和相角  $\theta$  马尔科夫链的 G-R 收敛性诊断比较结果。其中每个输出随机变量均由 5 条相互独立的马尔科夫链组成。由图 3 可以得出, 切片采样法仅经过 1 400 次采样(“退火”后)就可达到收敛, 而 Gibbs 采样法却要进行 2 600 次采样(“退火”后)才能收敛。可见, 切片采样法的收敛速度要快于 Gibbs 采样法。




图 3 两种采样方法的 Gelman-Rubin 诊断比较

Fig. 3 Comparison of Gelman-Rubin diagnostics for the two sampling methods

### 4.2 算法的稳定性比较

以 3 号节点电压幅值  $V$  为例对切片采样算法和 Gibbs 采样算法的稳定性进行比较。图 4 和图 5 分别为两种采样算法经过 5 次独立计算得出的电压幅值期望  $E[f_V(x)]$  的收敛曲线。





图 4 切片采样生成的  $E[f_V(x)]$  的收敛曲线

Fig. 4 Convergence plot of  $E[f_V(x)]$  by slice sampling

图5 Gibbs 采样生成的  $E[f_V(x)]$  的收敛曲线Fig. 5 Convergence plot of  $E[f_V(x)]$  by Gibbs sampling

由图4和图5可以看出: 在每条链收敛之前, 切片采样算法得出的5条马尔科夫链的期望收敛曲线彼此差距较小, 而Gibbs采样算法得出的期望收敛曲线波动范围比较大; 在所有链收敛之后, 切片采样法得出的每条马尔科夫链期望的最终收敛值非常接近, 而Gibbs采样算法得出的每条链的最终收敛值彼此相差比较大。由此可知, 切片采样算法在整个采样过程中的稳定性都强于Gibbs采样算法。

#### 4.3 算法的准确度比较

为了量化分析两种采样算法的计算准确度, 假设采用Gibbs采样算法进行105 000次迭代计算, 前5 000次用于“退火”, 后100 000次采样结果作为精确值, 计算出的节点电压  $V$  (相角  $\theta$ ) 期望和标准差分别用  $\mu_{V(\theta) \text{ accurate}}$  和  $\sigma_{V(\theta) \text{ accurate}}$  表示。同样地, 用  $\mu_{V(\theta) \text{ simulated}}$  和  $\sigma_{V(\theta) \text{ simulated}}$  表示“退火”后在采样3 000次的情况下输出的随机变量的期望和方差。输出随机变量的准确度可以用其期望值和标准差的相对误差来衡量<sup>[24]</sup>。

$$\mathcal{E}_{V(\theta) \mu} = \left| \frac{\mu_{V(\theta) \text{ accurate}} - \mu_{V(\theta) \text{ simulated}}}{\mu_{V(\theta) \text{ accurate}}} \right| \times 100\% \quad (15)$$

$$\mathcal{E}_{V(\theta) \sigma} = \left| \frac{\sigma_{V(\theta) \text{ accurate}} - \sigma_{V(\theta) \text{ simulated}}}{\sigma_{V(\theta) \text{ accurate}}} \right| \times 100\% \quad (16)$$

由于在概率潮流计算中输出随机变量的个数很多, 因此采用相对误差的平均值  $\bar{\mathcal{E}}_{V(\theta) \mu}$  和  $\bar{\mathcal{E}}_{V(\theta) \sigma}$  来表示整个系统的输出随机变量的误差。

表2给出了两种采样方法分别计算得出的节点电压幅值和相角的期望和标准差的相对误差平均值。从表2可知, 在采样3 000次的情况下, 切片采样算法计算出的各相对误差平均值远小于Gibbs采样算法得出的各相对误差平均值, 由此说明了本文所提方法的精确性。

表2 输出随机变量的误差均值比较

Tab. 2 Average error comparisons of output random variables

算法		$\bar{\mathcal{E}}_{V \mu} (\%)$	$\bar{\mathcal{E}}_{V \sigma} (\%)$	$\bar{\mathcal{E}}_{\theta \mu} (\%)$	$\bar{\mathcal{E}}_{\theta \sigma} (\%)$
Gibbs	最大值	0.047	6.218	2.067	5.877
	均值	0.009	2.349	1.102	3.681
切片采样	最大值	$2.7 \times 10^{-4}$	3.958	0.036	3.375
	均值	$2.3 \times 10^{-4}$	1.914	0.011	1.962

## 5 结论

本文提出了一种基于切片采样算法的改进MCMC方法, 并用于风力发电并网系统概率潮流计算中。与传统MCMC方法相比, 引入辅助变量的切片采样方法能够显著提高MCMC方法的计算准确度。同时, 在与Gibbs算法采样迭代次数相同的情况下, 切片采样算法所生成的马尔科夫链可以更快、更稳定地收敛于平稳分布。通过对含有风电场概率模型的IEEE 39节点系统进行仿真, 验证了本文提出方法的精确性和有效性。

## 参考文献

- [1] 陈谦, 陈霄逸, 金宇清, 等. 基于混合储能的大型风电场优化控制[J]. 电力自动化设备, 2015, 35(4): 70-76.  
Chen Qian, Chen Xiaoyi, Jin Yuqing, et al. Optimal control of large-scale wind farm based on hybrid energy storage[J]. Electric Power Automation Equipment, 2015, 35(4): 70-76.
- [2] 金海峰, 吴涛. 风电接入系统后的电压稳定问题[J]. 电力自动化设备, 2010, 30(9): 82-84.  
Jin Haifeng, Wu Tao. Voltage stability after grid-connection of wind farm[J]. Electric Power Automation Equipment, 2010, 30(9): 82-84.
- [3] Borkowska B. Probabilistic load flow[J]. IEEE Transactions on Power Apparatus and Systems, 1974, 93(3): 752-759.
- [4] Oke O A, Thomas D W P. Enhanced cumulant method for probabilistic power flow in systems with wind generation[C]//11th International Conference on Environment and Electrical Engineering (EEEIC), Venice, Italy, 2012: 849-853.
- [5] 董雷, 杨以涵, 张传成, 等. 综合考虑网络结构不确定性的概率潮流计算方法[J]. 电工技术学报, 2012, 27(1): 210-216.  
Dong Lei, Yang Yihan, Zhang Chuancheng, et al. Probabilistic load flow considering network configuration uncertainties[J]. Transactions of China Electrotechnical Society, 2012, 27(1): 210-216.
- [6] Saunders C S. Point estimate method addressing



- correlated wind power for probabilistic optimal power flow [J]. IEEE Transactions on Power Systems, 2014, 29(3): 1045-1054.
- [7] 吴巍, 汪可友, 韩蓓, 等. 基于 Pair Copula 的随机潮流三点估计法[J]. 电工技术学报, 2015, 30(9): 121-128.  
Wu Wei, Wang Keyou, Han Bei, et al. Pair Copula based three-point estimate method for probabilistic load flow calculation[J]. Transactions of China Electrotechnical Society, 2015, 30(9): 121-128.
- [8] 蔡德福, 石东源, 陈金富. 基于 Copula 理论的计及输入随机变量相关性的概率潮流计算[J]. 电力系统保护与控制, 2013, 41(20): 13-19.  
Cai Defu, Shi Dongyuan, Chen Jinfu. Probabilistic load flow considering correlation between input random variables based on Copula theory[J]. Power System Protection and Control, 2013, 41(20): 13-19.
- [9] Zhen S, Panida J, Armando M, et al. Accelerated state evaluation and Latin hypercube sequential sampling for composite system reliability assessment[J]. IEEE Transactions on Power Systems, 2014, 29(4): 1692-1700.
- [10] 茆美琴, 周松林, 苏建徽. 基于风光联合概率分布的微电网概率潮流预测[J]. 电工技术学报, 2014, 29(2): 55-63.  
Mao Meiqin, Zhou Songlin, Su Jianhui. Probabilistic power flow forecasting of microgrid based on joint probability distribution about wind and irradiance[J]. Transactions of China Electrotechnical Society, 2014, 29(2): 55-63.
- [11] 石文辉, 别朝红, 王锡凡. 大型电力系统可靠性评估中的马尔可夫链蒙特卡洛方法[J]. 中国电机工程学报, 2008, 28(4): 9-15.  
Shi Wenhui, Bie Chaohong, Wang Xifan. Applications of Markov Chain Monte Carlo in large-scale system reliability evaluation[J]. Proceedings of the CSEE, 2008, 28(4): 9-15.
- [12] James C S. Estimation via Markov Chain Monte Carlo[J]. IEEE Control System Magazine, 2003, 23(2): 35-45.
- [13] Muller O, Yang M Y, Rosenhahn B. Slice sampling particle belief propagation[C]//International Conference on Computer Vision, Sydney, 2013: 1129-1136.
- [14] Neal R M. Slice sampling[J]. Annals of Statistics, 2003, 31(3): 705-767.
- [15] 戎晓雪, 别朝红, 石文辉, 等. 考虑风电场相关性的含风电电力系统随机潮流分析[J]. 电网技术, 2014, 38(8): 2161-2167.  
Rong Xiaoxue, Bie Chaohong, Shi Wenhui, et al. Analysis on probabilistic load flow in power grid integrated with wind farms considering correlativity among different wind farms[J]. Power System Technology, 2014, 38(8): 2161-2167.
- [16] 于鹏, 黎静华, 文劲宇, 等. 含风电功率时域特性的风电功率序列建模方法[J]. 中国电机工程学报, 2014, 34(22): 3715-3723.  
Yu Peng, Li Jinghua, Wen Jinyu, et al. A wind power time series modeling method based on its time domain characteristics[J]. Proceedings of the CSEE, 2014, 34(22): 3715-3723.
- [17] 蔺红, 孙立成, 常喜强. 新疆风电出力波动特性的概率建模[J]. 电网技术, 2014, 38(6): 1616-1620.  
Lin Hong, Sun Licheng, Chang Xiqiang. A probabilistic model to simulate wind power output fluctuation of a certain wind farm cluster in Xinjiang region[J]. Power System Technology, 2014, 38(6): 1616-1620.
- [18] Dempster A P, Laird N M, Rubin D B. Maximum likelihood from incomplete data via the EM algorithm[J]. Journal of the Royal Statistical Society, 1977, 39(1): 1-38.
- [19] 王平波, 蔡志明, 刘旺锁. 混合高斯概率密度模型参数的期望最大化估计[J]. 声学技术, 2007, 26(3): 498-502.  
Wang Pingbo, Cai Zhiming, Liu Wangsuo. EM estimation of PDF parameters for Gaussian mixture processes[J]. Technical Acoustics, 2007, 26(3): 498-502.
- [20] Besag J, Green P J. Spatial statistics and Bayesian computation[J]. Journal of the Royal Statistical Society, 1993, 55(1): 25-37.
- [21] 50Hertz Transmission GmbH. Grid data [DB/OL]. [2013-07-14]. <http://www.50hertz.com/en/Netzkennzahlen.htm>.
- [22] Gelman A, Rubin D. Inference from iterative simulation using multiple sequences[J]. Statistical Science, 1992, 7(4): 457-511.
- [23] Bocquel M, Papi F, Podt M, et al. Multitarget tracking with multiscan knowledge exploitation using sequential MCMC sampling[J]. IEEE Journal of Selected Topics in Signal Processing, 2013, 7(3): 532-542.
- [24] Chen Y, Wen Jinyu, Cheng Shijie. Probabilistic load flow method based on Nataf transformation and Latin hypercube sampling[J]. IEEE Transactions on Sustainable Energy, 2013, 4(2): 294-301.

#### 作者简介

张晓英 女, 1973 年生, 硕士, 副教授, 研究方向为电力系统电压稳定性。

E-mail: 245659219@qq.com(通信作者)

王 琨 男, 1988 年生, 硕士研究生, 研究方向为电力系统分析与稳定控制。

E-mail: 471943808@qq.com