

文章编号: 1673-5196(2018)01-0085-06

基于 DAEM 算法的风力发电并网 系统概率潮流计算

张晓英^{1,2,3}, 王琨⁴, 汪彬^{1,2,3}, 王晓兰^{1,2,3}, 陈伟^{1,2,3}

(1. 兰州理工大学 电气工程与信息工程学院, 甘肃 兰州 730050; 2. 兰州理工大学 甘肃省工业过程先进控制重点实验室, 甘肃 兰州 730050; 3. 兰州理工大学 国家级电气与控制工程实验教学中心, 甘肃 兰州 730050; 4. 国网甘肃省电力公司 电力科学研究院, 甘肃 兰州 730050)

摘要: 针对基于加权高斯混合分布(WGMD, weighted Gaussian mixture distribution)构建风电场概率模型的方法中, EM(expectation maximization)算法由于其固有缺陷导致整个模型拟合精度降低的问题, 提出基于 DAEM(deterministic annealing expectation maximization)算法的风电场概率建模方法, 并结合马尔科夫链蒙特卡洛(MCMC, Markov Chain Monte Carlo)模拟法进行风力发电并网系统概率潮流计算. DAEM 算法通过引入退火机制, 避免了在模型参数最大似然估计时, EM 算法容易陷入局部最优的问题, 使得风电场模型更加准确. 在接有风电场的 IEEE 39 节点系统中进行概率潮流计算, 计算结果证明了所提算法的精确性和有效性.

关键词: 风电并网; 概率潮流; 加权高斯混合分布; MCMC; EM; DAEM

中图分类号: TM614 **文献标志码:** A

Probabilistic load flow calculation based on DAEM algorithm for wind-farm integration system

ZHANG Xiao-ying^{1,2,3}, WANG Kun⁴, WANG Bin^{1,2,3}
WANG Xiao-lan^{1,2,3}, CHEN Wei^{1,2,3}

(1. College of Electrical and Information Engineering, Lanzhou Univ. of Tech., Lanzhou 730050, China; 2. Key Laboratory of Gansu Advanced Control for Industrial Processes, Lanzhou Univ. of Tech., Lanzhou 730050, China; 3. National Experimental Teaching Center of Electrical and Control Engineering, Lanzhou Univ. of Tech., Lanzhou 730050, China; 4. Electric Power Research Institute, State Grid Gansu Electric Power Company, Lanzhou 730050, China)

Abstract: Aimed at the problem happened to the probability model of wind-farm built up with weighted Gaussian mixture distribution (WGMD) algorithm that the EM (expectation maximization) algorithm will lead entire model fitting precision to lower due to its inherent defect, a method for probability modeling of wind-farm is proposed based on DAEM (deterministic annealing expectation maximization) algorithm and integrated into MCMC (Markov Chain Monte Carlo) simulation method to conduct the computation of probabilistic load flow of wind farm integration system. When the maximum likelihood estimation of wind farm modeling parameters is being made, the DAEM algorithm by means of introducing an annealing mechanism, can avoid such problem that EM algorithm would easily lead to converging to local optimum, in order to make the model of wind-farm even more accurate. The probability flow calculation is performed in IEEE 39 bus system connected with the wind-farm, and it is verified by the calculation result that the proposed algorithm will be accurate and valid.

Key words: wind-farm integration; probability load flow; weighted Gaussian mixture distribution; MCMC; EM; DAEM

收稿日期: 2016-06-08

基金项目: 国家自然科学基金(51267012)

作者简介: 张晓英(1973-)女, 四川仁寿人, 硕士, 副教授.

由于风力发电技术日趋成熟, 同时发电成本不断降低, 因此它已成为新能源发电中发展前景最为广阔的一种发电方式. 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. 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^[1].

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. 确定性潮流分析法由于要考虑风电变化的所有可能性, 因此需要耗费大量的计算时间, 且计算结果很难全面反映并网系统的真实情况^[2]. 而克服了上述方法缺陷的概率统计法成为了分析风电并网系统的基本方法. 20 世纪 70 年代 Borkowska^[3] 首次提出概率潮流 (probabilistic load flow, PLF) 计算的概念, 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. 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, 这些方法大体可分为解析法^[4]和模拟法^[5].

基于解析法的概率潮流计算主要包括半不变量法和点估计法. 这种方法计算效率高, 但是计算精度不高, 并且需要遵循参数之间相互独立的假设前提. 基于模拟法的概率潮流计算中, 蒙特卡洛模拟法 (Monte Carlo simulation, MCS) 最具有代表性. MCS 在采样规模足够大的情况下, 得到很高的计算精度, 这种方法大多作为验证其他方法准确程度的标准.

现有风电并网系统概率潮流研究中风电场概率模型的建立方法主要有两种: 一种是基于 Weibull 分布^[6] 的风速概率密度函数的建模方法; 另一种是基于时间随机序列的方法即采用差分自回归滑动平均 (auto-regressive and moving average, ARMA) 模型^[7] 和 MCMC 方法^[8] 进行序列建模. 基于风速概率密度函数建模法在风电场规模较小的情况下可以满足计算效率和精度的要求, 因此被广泛用于中长期概率潮流评估当中. 然而其所采用的单一风速采样数据和基于单个风机的功率输出模型的简单等效叠加无法真实反映整个风电场功率变化的情况, 并且这种拟合误差随着风电场规模的扩大而增大. 对于时间随机序列的方法来说, 由于直接采用风电场总功率的实测数据作为拟合对象, 因此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. 但是该方法需要大量的风电场实测数据作为支撑, 因此其适用范围受到了局限.

一些学者在总结了风电场概率建模的缺陷后, 提出了基于加权高斯混合分布 (weighted Gaussian mixture distribution, WGMD)^[9-10] 的风电场出力波

动特性的概率建模方法. 该方法采用多个不同权值的高斯分布拟合风电场输出功率的概率特性, 同时保留了风电场内部的非线性相关性, 因此显著提高了风电场出力波动性模拟的精度^[9]. 然而蔺红等^[9-10] 在求取加权高斯混合模型参数时采用的 EM (expectation maximization) 算法存在收敛性缺陷, 从而导致最终的结果相较于实测数据的计算结果有明显的偏差. 针对 EM 算法的不足, Mori 等^[11] 提出一种 EM 算法的改进算法 DAEM (deterministic annealing expectation maximization), 并应用于概率潮流计算中, 其研究结果表明 DAEM 算法可以显著改善 EM 算法收敛于局部最优的缺陷. 但是该文献只考虑了负荷的概率分布特性, 并没有关注新能源发电的随机特性对并网系统的影响. 同时该文献只是简要提出了 DAEM 算法的计算思想, 并未对该算法在概率潮流计算中的具体迭代步骤和关键参数做详细介绍, 因此其可行性和适用性有待进一步考究.

针对文献^[11] 的不足, 本文建立了基于加权高斯混合分布的风电场概率模型, 采用 DAEM 算法^[11-12] 求取加权高斯混合分布的风电场概率模型中的未知参数, 详细介绍了关键参数 (温度系数 β) 的取值和该算法在风电并网系统概率潮流计算中的具体计算流程. 最后, 通过对德国某地区两个相邻风电场有功出力的概率建模和在接有风力发电的 IEEE 39 节点系统中进行概率潮流计算, 对比结果证明了本文所提算法的精确性和有效性.

1 风电场概率模型的建立

1.1 基于加权高斯混合分布的风电场概率模型

加权高斯混合分布是进行数据分析的一种基本模型, 其广泛应用于机器学习、模式识别和图像处理等领域. 该分布采用多个高斯分布的加权组合可以拟合出各种概率分布, 因此非常适合描述像风电功率波动这样无法用某种特定概率分布表示的概率模型. 以加权高斯混合分布来描述风电场出力的概率密度函数可表示为

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

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.

1.2 EM 算法

蔺红等^[9-10]采用了传统求解加权高斯混合分布未知参数的 EM 算法. 当风电场实测出力已知, 也就是描述风电场出力的加权高斯混合分布的观察值 $X = \{x_1, x_2, \dots, x_N\}$ 给定后, 该概率分布的似然函数为

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

式中: $\Theta = \{\theta_1, \theta_2, \dots, \theta_N\}$. 对式(2)取对数得

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

则 EM 算法进行风电场出力概率分布的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:

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

M 步: 寻找 $\Theta^{(p+1)}$ 使得

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

循环迭代 E 步和 M 步直到满足 $\left| \frac{\Theta^{(p+1)} - \Theta^{(p)}}{\Theta^{(p)}} \right| \leq \epsilon$

的收敛条件结束, 就可以得到风电场出力概率分布的未知参数.

1.3 DAEM 算法

虽然在设定风电场出力的实测数据后就可通过 EM 算法得到描述风电场出力的加权高斯混合分布未知参数. 但是受到初始条件的影响, EM 算法的输出结果不一定能够收敛到全局最优^[12]. DAEM 算法只是对 EM 算法的迭代公式进行少许改进就可以避免在求取未知参数时陷入局部最优.

在 EM 算法中, 由于后验概率密度函数在迭代的初始阶段不可靠, 因此根据最大熵定则, Ueda 等^[12]提出了一个新的后验概率密度函数, 且服从 Gibbs 分布:

$$G(\omega | X) = \frac{1}{Z} \exp\{-\beta(-L_c(\Theta | X, \omega))\} \quad (6)$$

式中: ω 为隐变量; $L_c(\Theta | X, \omega)$ 为完全数据的对数似然函数:

$$L_c(\Theta | X, \omega) = \log f(X, \omega) \quad (7)$$

Z 为分离函数:

$$Z = \int \exp\{-\beta(-L_c(\Theta | X, \omega))\} d\omega = \int f(X, \omega)^\beta d\omega \quad (8)$$

式中: β 为对应于退火温度倒数的温度系数. 同样根据贝叶斯理论, 通过式(6)和式(8)可以得到一个新的以 Θ 和 X 为条件关于 ω 的后验概率密度函数:

$$G(\omega | X, \Theta) = \frac{f(X, \omega)^\beta}{\int f(X, \omega)^\beta d\omega} \quad (9)$$

在 DAEM 算法中完全数据似然函数的条件期望定义为

$$U_\beta(\Theta | \Theta^{(p)}) = E_{G^{(p)}} \{-\log f(X, \omega) | X, \Theta^{(p)}\} = - \sum_{n=1}^N \sum_{m=1}^M \omega_{nm}^{(p)} \log \{\alpha_m G_m(x_n | \theta_m)\} \quad (10)$$

$$\omega_{nm}^{(p)} = \frac{[\alpha_m^{(p)} G_m(x_n | \theta_m^{(p)})]^\beta}{\sum_{m=1}^M [\alpha_m^{(p)} G_m(x_n | \theta_m^{(p)})]^\beta} \quad (11)$$

由式(11)可以看出, 当引入温度系数 β 后, 其对似然函数起到了平滑的作用. 随着迭代的进行, 退火温度逐渐降低, 而熵逐渐增大, 同时温度系数 β 也增大. 直到 $\beta=1$ 迭代停止, 就可以得到基于最大熵的最大似然估计值. 根据式(6~11)的推导, DAEM 算法流程如下:

1) 初始化迭代参数 $\Theta^{(0)}$ 和温度参数 $\beta = \beta_{\min}$, 其中 $0 < \beta_{\min} \leq 1$;

2) 迭代计算如下参数, 直到收敛:

$$\left\{ \begin{aligned} \alpha_m^{(p+1)} &= \frac{1}{N} \sum_{n=1}^N \omega_{nm} \\ \mu_m^{(p+1)} &= \frac{\sum_{n=1}^N \omega_{nm} \cdot x_n}{\sum_{n=1}^N \omega_{nm}} \\ [\sigma_m^{(p+1)}]^2 &= \frac{\sum_{n=1}^N \omega_{nm} \cdot (x_n - \mu_m^{(p+1)})^2}{\sum_{n=1}^N \omega_{nm}} \\ \omega_{nm} &= \frac{[\alpha_m \cdot G_m(x_n | \theta_m^{(p)})]^\beta}{\sum_{m=1}^M [\alpha_m \cdot G_m(x_n | \theta_m^{(p)})]^\beta} \end{aligned} \right. \quad (12)$$

3) 更新温度参数 $\beta = \beta \cdot \beta_{\text{rate}}$, 其中 β_{rate} 为迭代步长;

4) 如果 $\beta < 1$ 则重复第(2)步, 否则停止.

由迭代流程可以看出, 与 EM 算法不同的是, DAEM 算法在每个温度下 ($1/\beta$) 对目标函数求取最小值. 而这也是为了区别于模拟退火算法, DAEM 算法被称之为确定性退火算法的原因所在. DAEM 算法的寻优速度由温度系数的迭代步长系数 β_{rate} 所决定, β_{rate} 越大则算法的寻优速度越快, 但是过大的迭代步长无法保证 DAEM 算法收敛到全局最优. 因此兼顾寻优速度与寻优精度, 在实际应用当中 β_{rate} 在区间 $[1.1, 1.5]$ 内取值. 值得注意的是, 当 $\beta=1$ 时, $U_\beta = -Q$, 此时 DAEM 算法就变成了 EM 算法.

2 风力发电并网系统概率潮流计算

本文提出了一种基于 DAEM 算法的改进 MC-MC 方法,并应用于风力发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:根据 1.1 节描述的加权高斯混合模型,风电场出力的概率密度函数为

$$f_{wind}(x) = \sum_{m=1}^M \alpha_m \frac{1}{\sqrt{2\pi}\sigma_m} e^{-\frac{(x-\mu_m)^2}{2\sigma_m^2}} \quad (13)$$

将风电场有功出力实测数据作为观察数据 $X = \{x_1, x_2, \dots, x_N\}$ 代入式(12)进行 DAEM 算法迭代,计算出风电场出力的概率密度函数中的未知参数 α_m 、 μ_m 、 σ_m^2 ;

2) 风电场功率样本生成:假设采样规模为 L ,采用 Gibbs 采样算法对风电场出力概率密度函数 $f_{wind}(x)$ 和服从正态分布的负荷模型 $f_{load}(x)$ 进行采样得到各变量的样本空间 $[P_{wind}, P_{load}, Q_{load}]$.假设风力发电机组采用恒功率因数控制($\cos \varphi = 0.9$):

$$Q_{wind} = P_{wind} \cdot \tan \varphi \quad (14)$$

根据式(14)求出风电场无功功率的样本空间 Q_{wind} ,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) 风电并网系统概率潮流计算:把样本空间 $[P_{wind}, Q_{wind}, P_{load}, Q_{load}]$ 中各组样本值循环代入常规潮流计算当中求出各节点和支路的潮流样本,从而得到输出随机变量的样本空间;

4) 潮流计算指标的概率评估: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.

3 算例分析

3.1 风电场模型精度分析

为验证分析 DAEM 算法所构建的风电场模型的精确性,本文以德国某地区两个相邻风电场(分别用 WF-A 和 WF-B 表示)1 年的实测出力数据为基准^[13],分别利用 EM 算法和 DAEM 算法建立两个风电场出力的概率模型.再对这两种不同算法构建的风电场模型进行采样,生成样本容量为 K 的概率潮流输入样本.采用风电场有功出力 P_{wind} 的数字特征 S 的相对误差 $\epsilon_{P_{wind},S}$ 来评价采样所得样本与实测数据之间的近似程度:

$$\epsilon_{P_{wind},S} = \left| \frac{S_{P_{wind},accurate} - S_{P_{wind},simulated}}{S_{P_{wind},accurate}} \right| \times 100\% \quad (15)$$

式中:accurate 和 simulated 分别代表风电场有功出力的实测数据和经过迭代运算得到的样本数据; S

代表风电场样本数字特征类型,包括期望 μ 、标准差 σ 、偏度系数 SKEW 和峰度系数 KURT^[14].与此同时,采用均方根误差(root mean squared error, RMSE)^[9]来评价各建模算法的收敛精度.

由于 MCMC 模拟过程具有一定随机性,为了对两种风电场概率模型进行准确评估,在确定采样规模 L 下对每一个输入随机变量进行采样得到 10 条马尔科夫链,代入计算后取误差结果的平均值 $\bar{\epsilon}_{P_{wind},S}$ 作为风电场有功出力样本的最终误差指标.

根据已有研究成果可知,在风电场规模较小的情况下,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波动^[10].因此本文采用一维二分量加权高斯混合模型来分别拟合两个风电场有功出力.风电场有功出力概率分布为

$$f(x) = \alpha_1 \frac{1}{\sqrt{2\pi}\sigma_1} e^{-\frac{(x-\mu_1)^2}{2\sigma_1^2}} + \alpha_2 \frac{1}{\sqrt{2\pi}\sigma_2} e^{-\frac{(x-\mu_2)^2}{2\sigma_2^2}} \quad (16)$$

通过如前所述方法分别采用 EM 算法和 DAEM 算法求取式(16)所代表的风电场 WF-A 和 WF-B 的各未知参数(见表 1).以风电场 WF-A 为例,风电出力实测数据以及分别采用不同算法计算所得风电功率的概率密度分布曲线如图 1 所示.在迭代过程中 DAEM 算法的温度系数初始值 $\beta_{min} = 0.1$,步长系数 $\beta_{rate} = 1.2$.

表 1 风电场概率模型参数估计值

Tab. 1 Parameter estimation values of wind-farm probability models

模型参数	EM 算法		DAEM 算法	
	WF-A	WF-B	WF-A	WF-B
α_1	0.681 7	0.683 5	0.628 6	0.621 7
α_2	0.318 3	0.316 4	0.371 4	0.378 3
μ_1	2.988 5	3.016 9	3.174 7	3.284 1
μ_2	3.825 6	3.906 3	3.998 4	4.019 7
σ_1	0.379 5	0.365 3	0.215 3	0.209 6
σ_2	0.691 2	0.700 6	0.505 6	0.496 3

根据 MCMC 理论,在经过 L 次采样迭代后保留后 K 次采样值(也称为“退火”)所得到的马尔科夫链收敛于平稳分布.为了控制采样规模同时保证概率模型的精确性和稳定性,本文采用 Gelman-Rubin(G-R)诊断方法^[15]确定 MCMC 方法中总采样次数 $L = 5\ 000$ 且保留采样规模 $K = 3\ 000$.表 2 为经过采样后风电场有功出力样本的各项误差平均值.

比较表 1 中的加权系数可以看出,EM 算法得到的 α_1 大于 DAEM 算法所求得值,而 α_2 小于 DAEM 算法求取的对应值.同时 EM 算法计算出的各分量均值 μ 均小于 DAEM 算法所求值.由此可得




图 1 风电功率概率密度分布

Fig. 1 Probability density distribution of wind-farm power output

基于 EM 算法构建的风电场概率模型过于侧重一分量影响而忽视了二分量的作用,并且各分量所求均值较小从而导致整个风电场概率模型过于保守.产生这种偏差最主要的原因是由于 EM 算法在参数估计时只能收敛到局部最优.而 DAEM 算法在引入温度系数后克服了 EM 算法的缺陷,使得参数估计值达到全局最优,这种优势可以在比较图 1 中的各概率密度分布后得出.

表 2 风电场有功出力样本平均相对误差

Tab. 2 Average relative error of wind-farm active power output samples

算法	$\bar{\epsilon}_{P_{wind},\mu}$	$\bar{\epsilon}_{P_{wind},\sigma}$	$\bar{\epsilon}_{P_{wind},SKEW}$	$\bar{\epsilon}_{P_{wind},KURT}$	V_{RMSE}
EM 算法	0.013	0.118	19.756	5.603	1.035
DAEM 算法	0.009	0.083	10.375	2.393	0.496
Weibull 建模法	0.124	0.366	28.311	7.198	1.947

从表 2 中可以看出:基于 EM 算法的样本误差最大值为 19.756、收敛精度为 1.035,基于 DAEM 算法的样本误差最大值为 10.375、收敛精度为 0.496;从总体来看,虽然在风电场有功出力样本均值和标准差的平均相对误差上 EM 算法和 DAEM 算法所求结果比较接近,但是基于 EM 算法的风电场概率模型不能很好反映风电场内部固有的非线性相关性,从而导致样本的偏度系数、峰度系数和收敛精度的平均相对误差较大;基于 Weibull 分布的风电场建模法的样本误差最大值为 28.311,比采用加权高斯混合模型的风电场建模法产生的样本误差要高出很多.此外,两个风电场出力之间的 KL 散度(Kullback-Leibler divergence)^[16]分别为 0.436(实际风电场出力)、0.512(EM 算法)、0.484(DAEM 算法)和 0.776(Weibull 建模法),显然基于 DAEM 算法得到的样本相关程度与实际风电场数据的相关程度更为接近.根据以上结果表明,相比于 Weibull 建模法和 EM 算法

建立的风电场有功出力模型样本,DAEM 算法构建的概率模型样本与实际风电场出力更吻合.

3.2 风电并网系统概率潮流计算与分析

本文以 IEEE 39 节点系统为算例,采用基于 MATLAB 的 Matpower5.0b1 电力系统计算工具包进行编程计算,对三种方法分别进行潮流计算分析.系统中包括 10 台发电机、12 台变压器、34 条线路和 39 个节点,其中节点 3、18、25、26 和 28 的有功功率和无功功率为服从正态分布且具有相关性的输入随机变量,且其具体参数来源于实测数据^[17].为研究风力发电并网对电力系统潮流的影响,将节点 30 和节点 37 处的常规发电机组分别换为 3.1 节算例中的两个风电场 WF-A 和 WF-B.类似于 3.1 节中使用的计算结果精度评估方法,本算例采用概率潮流计算后输出随机变量的数字特征平均相对误差和最大相对误差来衡量计算结果的精确性,并且将风电场有功出力实测数据代入潮流计算后得到的输出随机变量结果作为准确值.

参考风电场有功出力样本生成容量,分别对负荷随机变量进行采样生成概率潮流计算所需输入随机变量样本,然后执行潮流计算程序.表 3 是 EM-MCMC 方法、DAEM-MCMC 方法和 Weibull 建模法进行概率潮流计算后得出的输出随机变量的平均相对误差指标.

表 3 输出随机变量平均相对误差

Tab. 3 Average relative error of output random variables

算法	输出随机变量	$\bar{\epsilon}_{\mu}$ %	$\bar{\epsilon}_{\sigma}$ %	$\bar{\epsilon}_{SKEW}$ %	$\bar{\epsilon}_{KURT}$ %
EM 算法	电压幅值	0.087	4.159	21.356	7.696
	电压相角	0.093	4.352	22.265	8.185
DAEM 算法	电压幅值	0.079	4.025	15.692	2.328
	电压相角	0.080	4.142	16.024	3.683
Weibull 建模法	电压幅值	0.121	7.336	29.874	11.917
	电压相角	0.115	7.584	29.967	12.385

由表 3 可知,在采样规模为 $K=3\ 000$ 时,三种算法模拟产生的样本所得到的概率潮流结果中,输出随机变量的期望和标准差的平均相对误差比较接近,但是峰度系数和偏度系数的平均相对误差差别较大,这与 3.1 节中风电场概率模型的评估结果一致.对比三种算法所得到的误差结果可知,DAEM 算法所得到的风电场概率样本优于 EM 算法和 Weibull 建模法所得到的样本.该结果表明本文所提基于 DAEM 算法的概率潮流计算精度高于基于 EM 算法和 Weibull 建模法.

进一步地,以节点电压幅值的概率分布为例,考察不同算法得出的结果对系统运行评估的区别.图

2和图3给出了受风电并网影响较大的25号节点电压幅值的PDF(probability density function)曲线和CDF(cunulative density function)曲线。由曲线图可以看出,EM-MCMC算法所得结果的节点电压中压概率被高估,而Weibull建模法所得结果的节点电压低压概率被低估、高压概率被夸大。因此EM-MCMC方法和Weibull建模法得到的结果不能真实反映节点电压的波动情况,而DAEM-MCMC方法计算出的概率分布特性最接近于实际电力系统潮流变化情况。因此本文所提方法不但能够应用于分析不确定性因素对电网潮流的影响,还能够应用于风电并网系统薄弱节点的潜在风险评估。

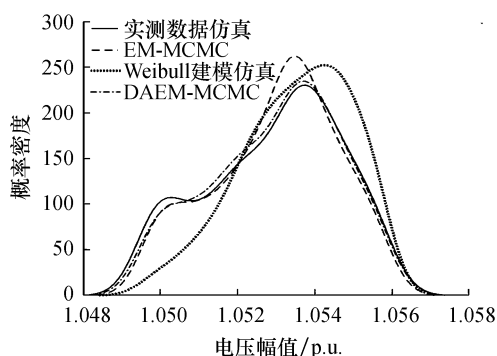


图2 电压幅值的概率密度分布曲线

Fig. 2 Probability density distribution curve of voltage amplitude

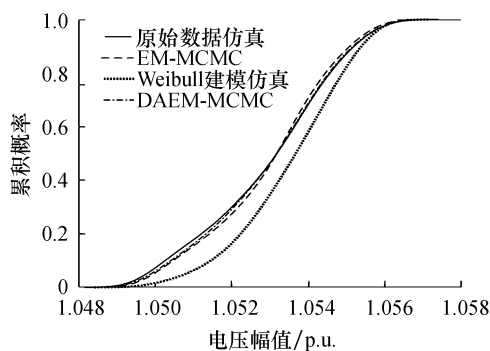


图3 电压幅值的累积概率分布曲线

Fig. 3 Cumulative probability distribution curve of voltage amplitude

4 结论

本文提出了一种基于DAEM算法的改进MC-MC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,本文所提方法具有如下特性:

1) 通过DAEM算法构建的输入随机变量的加权高斯混合模型保留了变量内部的非线性相关性,从而使得概率计算结果更加精确。

2) 相对于EM算法,DAEM算法引入了温度系数 β 降低了对初始值的敏感程度,从而在进行最大似然估计时可以达到全局最优。

通过对接有风电的IEEE 39节点系统进行概率潮流计算验证了本文提出方法的精确性和有效性。

参考文献:

- [1] 张晓英,张 璞.基于PQ曲线的风电并网系统电压稳定性评估[J].兰州理工大学学报,2015,41(4):95-98.
- [2] 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.
- [3] BORKOWSKA B. Probabilistic load flow [J]. IEEE Trans on Power Apparatus and Systems,1974,93(3):752-759.
- [4] 朱星阳,刘文霞,张建华.考虑大规模风电并网的电力系统随机潮流[J].中国电机工程学报,2013,33(7):77-85.
- [5] 潘 雄,张 龙,黄家栋,等.基于数字网系方法的概率最优潮流计算[J].电力系统自动化,2015,39(7):35-40.
- [6] 高元海,王 淳.基于全概率公式的含风电电力系统概率潮流计算[J].中国电机工程学报,2015,35(2):327-334.
- [7] 张文韬,王秀丽,吴 雄,等.大规模风电接入下含大用户直购电的电力系统调度模型研究[J].中国电机工程学报,2015,35(12):2927-2935.
- [8] 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.
- [9] 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.
- [10] 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.
- [11] MORI H, JIANG Wenjun. A new probabilistic load flow method using MCMC in consideration of nodal load correlation [C]//15th International Conference on Intelligent System Applications to Power Systems. New Jersey: IEEE Computer Society,2009:1-6.
- [12] UEDA N, NAKANO R. Deterministic annealing EM algorithm [J]. Neural Networks,1998,11:271-282.
- [13] TRANSNET BW. Res plant data [EB/OL]. [2014-07-14]. <https://www.transnetbw.com/en/res-kwkg/res/res-plant-data>.
- [14] GEORGIOUO G M, VOIGT K. Stochastic computation of moments, mean, variance, skewness and kurtosis [J]. Electronics Letters,2015,51(9):673-674.
- [15] BOCQUEL M,PAPI F,PODT M, et al. Multitarget tracking with multiscan knowledge exploitation using sequential MC-MC sampling [J]. IEEE Journal of Selected Topics in Signal Processing,2013,7(3):532-542.
- [16] DASGUPTA S,PARAMASIVAM M,VAIDYA U, et al. Entropy-based metric for characterization of delayed voltage recovery [J]. IEEE Trans on Power Systems,2015,30(5):2460-2468.
- [17] Load data [EB/OL]. [2015-01-01]. http://www.nyiso.com/public/markets_operations/market_data/load_data/index.jsp.