

基于重要抽样与极限学习机的大电网可靠性评估

许鹏程¹, 刘文霞², 陈启³, 张浩¹

(1. 国网福建省电力有限公司福州供电公司, 福建 福州 350009;

2. 华北电力大学 新能源电力系统国家重点实验室, 北京 102206;

3. 国网浙江省电力公司宁波市供电公司, 浙江 宁波 315012)

摘要: 由于不确定因素多、电网规模大, 原始蒙特卡洛模拟(MCS)在复杂电力系统可靠性评估中无法满足实时高效的要求。提出一种基于交叉熵(CE)的重要抽样与极限学习机(ELM)相结合的可靠性评估算法, 一方面通过在系统抽样环节引入CE构建元件的最优概率分布, 减小方差变化, 加快指标收敛速度; 另一方面, 采用ELM对重要抽样的状态样本进行有监督学习, 以所构建的网络学习模型替代传统非线性规划方法进行状态评估, 提高单次系统状态评估的效率, 从而实现快速可靠性评估。对IEEE RTS-79系统进行可靠性评估, 与原始MCS和CE重要抽样的对比结果表明, 在一定的误差范围内所提算法合理、有效, 其计算效率较原始MCS和CE显著提高。

关键词: 可靠性评估; 重要抽样; 交叉熵; 极限学习机; 有监督学习

中图分类号: TM 73

文献标识码: A

DOI: 10.16081/j.issn.1006-6047.2019.02.030

0 引言

随着电力系统规模日益增大, 电气联系逐渐加强, 以及不确定性因素逐渐增多^[1], 基于蒙特卡洛模拟(MCS)的可靠性评估方法在高可靠性系统中的计算效率大幅降低。因此, 如何快速、准确地评估现代电力系统可靠性水平具有重要的现实意义。

为了改善MCS的收敛效果, 研究提出大量提高可靠性评估计算效率的方法, 主要包括改进抽样阶段以降低方差变化以及改进状态评估阶段以提高系统损失评价效率两方面^[2]。一方面, 前者通过在抽样环节引入分层抽样、重要抽样、等分散抽样等方法来降低方差变化, 其中重要抽样相对更为有效^[3]。文献[3]结合重要抽样和控制变量法提出重要控制算法, 应用于电力系统可靠性评估; 文献[4]基于重要抽样, 提出动态故障集快速索引, 并代替重复状态的最优潮流计算进行系统的快速可靠性评估; 文献[5]将重要抽样与分层抽样结合, 通过重要抽样求取系统元件新的概率分布, 基于新概率分布进行拉丁超立方抽样, 避免了系统正常状态的大量重复抽样。上述方法均以重要抽样为基础, 降低抽样方差, 不同程度上改善了MCS收敛效果。

另一方面, 系统状态评估问题的求解主要基于最优潮流(OPF), 属于非线性约束下的优化问题, 计算过程耗时较长^[4,6](占计算总时间的90%以上)。研究提出在状态评估中引入人工智能算法^[7], 将OPF计算与神经网络、支持向量机(SVM)等智能算法相结合, 以提高评估效率。这类方法采用模式识别对系统进行状态评估, 文献[8]通过构造SVM网络模型将系统状态分为正常状态和故障状态, 避免

了正常状态下无选择性的重复计算; 文献[9]通过样本训练构建神经网络学习模型, 并以该模型对新的系统状态样本进行状态估计, 从而加快系统状态评价速度。上述方法虽已应用到电力系统可靠性评估中, 但由于样本训练过程仍较为耗时, 且相比于原状态评估算法, 以网络学习模型对系统状态进行分类和预测必然会引入一定误差, 故计算速度和精度均有待提高^[10]。然而在实时电力系统可靠性评估中, 可靠性指标主要反映多场景多方案的对比与决策(即可靠性指标为一个相对值, 非绝对值), 对计算速度有较高的要求, 且允许一定的计算误差, 因此机器学习在电力系统可靠性评估的融合应用仍然有着广泛的研究前景。

近年来, 随着人工智能的发展, 研究提出许多高效的机器学习算法, 如AdaBoost、Random Forest、极限学习机ELM(Extreme Learning Machine)、受限玻尔兹曼机等, 这些算法已在电力系统得到广泛应用。文献[11-12]将SVM、随机森林等算法引入暂态稳定性评估; 文献[13]利用遗传算法和径向基函数(RBF)神经网络对离网状态下微网的负荷动态特性进行预测; 文献[14-15]通过建立偶发事件识别模式的神经网络模型, 对发输电组合系统进行可靠性评估。在众多机器学习算法中, ELM^[16]作为一种基于单隐层前馈神经网络的快速学习算法, 具备强大的监督学习能力, 文献[17]指出ELM的泛化能力与学习速度远高于SVM。目前, ELM已在电力负荷预测、暂态稳定评估等不同领域得到应用。本文结合电力系统可靠性状态评估过程特点, 引入ELM, 并将其与基于交叉熵CE(Cross-Entropy)的重要抽样相结合实现快速可靠性评估。

1 基于 MCS 法的可靠性评估及其改进

MCS 求解电力系统可靠性可以分为系统状态抽样、状态估计和可靠性指标统计 3 个步骤。

首先在系统状态空间 Ω 内对各元件进行抽样得到系统状态 \mathbf{X} , 通过状态评估选择其中处于故障状态的样本, 统计计算出系统的可靠性指标:

$$E(F) = \sum_{\mathbf{X} \in \Omega} F(\mathbf{X}) P(\mathbf{X}; \boldsymbol{\alpha}) \quad (1)$$

其中, $\boldsymbol{\alpha}$ 为参数向量; $P(\mathbf{X}; \boldsymbol{\alpha})$ 为随机样本 \mathbf{X} 的概率分布函数; $F(\mathbf{X})$ 为其可靠性指标计算函数。

本文主要对系统状态抽样、状态估计进行了改进。首先, 以 CE^[18] 优化构建元件(发电机和输电线路)可靠性参数的最优概率分布, 并以该分布进行非序贯 MCS 生成系统状态样本(包括元件状态和失负荷情况); 其次, 通过 ELM 的监督学习能力对系统状态样本集进行训练, 求解网络学习模型; 最后以所训练的 ELM 模型替代传统最优潮流进行状态评估, 通过 ELM 学习模型推导得到系统失负荷状况, 进而计算系统可靠性指标。

1.1 基于 CE 的重要抽样

当所求可靠性指标较小时, MCS 需要大量样本进行迭代, 因此引入重要抽样提高 MCS 计算效率。引入 CE 的重要抽样是一种处理小概率事件的有效方法, 其基本思想是通过样本学习的方式最小化 2 个目标函数的 KL(Kullback-Leibler) 距离^[19], 从而找到零方差概率分布函数的逼近函数, 利用该逼近函数采样即可达到减小样本方差的目的。对式(1)变形得到:

$$E(F) = \sum_{\mathbf{X} \in \Omega} \frac{F(\mathbf{X}) P(\mathbf{X}; \boldsymbol{\alpha})}{P(\mathbf{X}; \boldsymbol{\mu})} P(\mathbf{X}; \boldsymbol{\mu}) = \sum_{\mathbf{X} \in \Omega} F^*(\mathbf{X}) P(\mathbf{X}; \boldsymbol{\mu}) \quad (2)$$

其中, $\boldsymbol{\mu}$ 为引入的新参数向量; $P(\mathbf{X}; \boldsymbol{\mu})$ 为引入重要抽样后的新概率分布函数; $F^*(\mathbf{X}) = \frac{F(\mathbf{X}) P(\mathbf{X}; \boldsymbol{\alpha})}{P(\mathbf{X}; \boldsymbol{\mu})}$

为新概率分布下可靠性指标计算函数。为实现 $E(F)$ 的无偏估计, 在系统状态空间 Ω 抽样得到 N 个随机样本 $\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_N$, 那么:

$$\hat{E}(F) = \frac{1}{N} \sum_{i=1}^N F(\mathbf{X}_i) \frac{P(\mathbf{X}_i; \boldsymbol{\alpha})}{P(\mathbf{X}_i; \boldsymbol{\mu})} = \frac{1}{N} \sum_{i=1}^N F(\mathbf{X}_i) W(\mathbf{X}_i; n; P(\cdot; \boldsymbol{\alpha}); P(\cdot; \boldsymbol{\mu})) \quad (3)$$

其中, $\hat{E}(F)$ 为无偏估计量; n 为系统元件个数; $W(\mathbf{X}_i; n; P(\cdot; \boldsymbol{\alpha}); P(\cdot; \boldsymbol{\mu}))$ 为似然比 LR(Likelihood Ratio), 实现不同概率分布下所计算可靠性指标的映射, 其计算公式^[20]如式(4)所示。

$$W(\mathbf{X}_i; n; P(\cdot; \boldsymbol{\alpha}); P(\cdot; \boldsymbol{\mu})) = \frac{\prod_{j=1}^n (1 - P(X_{ij}; \boldsymbol{\alpha}))^{X_{ij}} P(X_{ij}; \boldsymbol{\alpha})^{1 - X_{ij}}}{\prod_{j=1}^n (1 - P(X_{ij}; \boldsymbol{\mu}))^{X_{ij}} P(X_{ij}; \boldsymbol{\mu})^{1 - X_{ij}}} \quad (4)$$

其中, $X_{ij} \in \mathbf{X}_i$ 取 0 或 1, 表示第 i 次抽样元件 j 的状态; $P(X_{ij})$ 为第 i 次抽样元件 j 故障的概率。若:

$$P(\mathbf{X}; \boldsymbol{\mu}) = F(\mathbf{X}) \frac{P(\mathbf{X}; \boldsymbol{\alpha})}{E(F)} \quad (5)$$

则 $\hat{E}(F)$ 的方差为 0, 此时对应的 $P(\mathbf{X}; \boldsymbol{\mu})$ 为最优概率分布函数, 记为 $P^*(\mathbf{X})$, 但是由于可靠性指标的期望 $E(F)$ 未知, 因此无法直接求解最优概率分布函数。为了解决该问题, 可以采用 CE 近似构造 $P^*(\mathbf{X})$, 即在概率分布函数 $P(\mathbf{X}; \boldsymbol{\alpha})$ 的分布簇中, 通过确定参数 $\boldsymbol{\alpha}$ 来选择与 $P^*(\mathbf{X})$ 的 KL 距离最近的概率分布函数作为其近似函数。根据 CE 就可以求得 KL 距离 $D(P^*(\mathbf{X}), P(\mathbf{X}; \boldsymbol{\alpha}))$ 为:

$$D(P^*(\mathbf{X}), P(\mathbf{X}; \boldsymbol{\alpha})) = \sum P^*(\mathbf{X}) \ln \frac{P^*(\mathbf{X})}{P(\mathbf{X}; \boldsymbol{\alpha})} = \sum P^*(\mathbf{X}) \ln P^*(\mathbf{X}) - P^*(\mathbf{X}) \ln P(\mathbf{X}; \boldsymbol{\alpha}) \quad (6)$$

通过最小化 KL 距离, 并以一定量样本寻优迭代, 最终求得最优概率分布函数 $P^*(\mathbf{X})$ 。详细推导见文献[18-19], 此处不再赘述。

本文在系统抽样环节引入 CE 优化过程, 根据元件对系统失负荷情况的贡献程度构建元件的最优概率分布, 并以该分布对系统状态进行采样, 提高了失负荷事件的发生率, 从而减小样本容量。因此基于 CE 的重要抽样能在保持可靠性指标值不变的条件下降低方差变化, 加快指标收敛效果。

1.2 引入 ELM 的系统状态评估

ELM^[21] 的网络模型采用前向单隐层神经网络结构, 如图 1 所示。

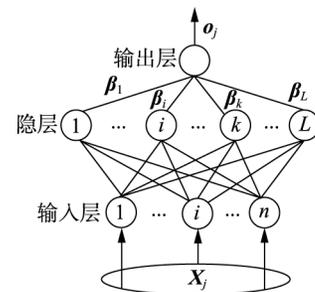


图 1 ELM 的网络训练模型

Fig.1 Network training model of ELM

假设有 N 个任意样本数据 $(\mathbf{X}_i, \mathbf{t}_i)$, 其中 $\mathbf{X}_i = [X_{i1}, X_{i2}, \dots, X_{in}]^T \in \mathbf{R}^n$; $\mathbf{t}_i = [t_{i1}, t_{i2}, \dots, t_{im}]^T \in \mathbf{R}^m$, 模型输入层、隐层和输出层的单元数分别为 n, L, m , 则 ELM 的网络模型可表示为:

$$\sum_{i=1}^L \beta_i g(\mathbf{W}_i \mathbf{X}_j + b_i) = o_j \quad (7)$$

其中, $j=1, 2, \dots, N$; $g(\cdot)$ 为激活函数; $\mathbf{W}_i = [w_{i1}, w_{i2}, \dots, w_{in}]$ 为输入权重; b_i 为第 i 个隐层单元的偏置; β_i 为输出权重; $\mathbf{o}_j = [o_{j1}, o_{j2}, \dots, o_{jm}]^T$ 为网络的输出。

在样本训练过程中, 隐层无需迭代, 且随机初始化输入层与隐层的权重矩阵 \mathbf{W}_i 和隐层偏置 b_i , 最后通过算法确定隐层输出权重, 定义训练样本的损失函数 G 为:

$$G(\theta) = \sum_{j=1}^N \|\mathbf{o}_j - \mathbf{t}_j\| = \|\mathbf{H}\boldsymbol{\beta} - \mathbf{T}\| \quad (8)$$

其中, $\theta = \{\mathbf{W}_i, \beta_i, b_i\}$; \mathbf{H} 为隐层输出矩阵; $\boldsymbol{\beta}$ 为输出权重矩阵; \mathbf{T} 为样本集期望输出矩阵。 \mathbf{H} 、 $\boldsymbol{\beta}$ 、 \mathbf{T} 的定义如下:

$$\mathbf{H}(\mathbf{W}_1, \dots, \mathbf{W}_L; b_1, \dots, b_L; \mathbf{X}_1, \dots, \mathbf{X}_N) = \begin{bmatrix} g(\mathbf{W}_1 \mathbf{X}_1 + b_1) & \dots & g(\mathbf{W}_L \mathbf{X}_1 + b_L) \\ \vdots & & \vdots \\ g(\mathbf{W}_1 \mathbf{X}_N + b_1) & \dots & g(\mathbf{W}_L \mathbf{X}_N + b_L) \end{bmatrix}_{N \times L} \quad (9)$$

$$\begin{cases} \boldsymbol{\beta} = [\beta_1 & \dots & \beta_L]^T_{L \times m} \\ \mathbf{T} = [\mathbf{t}_1 & \dots & \mathbf{t}_N]^T_{N \times m} \end{cases} \quad (10)$$

当隐层单元的激活函数无限可微时, 输入权重 \mathbf{W}_i 和隐层偏置 b_i 可随机确定, 此时隐层输出矩阵 \mathbf{H} 为常数矩阵, 则通过求解优化问题 $\min \{G(\theta)\}$, 最终可求解参数 $\boldsymbol{\beta}$ 的无偏估计量 $\hat{\boldsymbol{\beta}}$ 。那么, 训练单隐层神经网络问题可以转化为求解线性方程 $\mathbf{H}\boldsymbol{\beta} = \mathbf{T}$ 的最小二乘解 $\hat{\boldsymbol{\beta}}$, 即:

$$\hat{\boldsymbol{\beta}} = \mathbf{H}^+ \mathbf{T} \quad (11)$$

其中, \mathbf{H}^+ 为矩阵 \mathbf{H} 的 Moore-Penrose 广义逆。

对于一个未知标签的系统元件状态 \mathbf{X} , 可通过上述训练的网络学习模型推导其失负荷情况, 推导公式如下:

$$f(\mathbf{X}) = \hat{\boldsymbol{\beta}} \mathbf{H}(\mathbf{X}) \quad (12)$$

其中, $\mathbf{H}(\mathbf{X}) = [g(\mathbf{W}_1, b_1, \mathbf{X}), \dots, g(\mathbf{W}_L, b_L, \mathbf{X})]$ 为神经网络隐藏层关于 \mathbf{X} 的响应。

相比于抽样阶段的降低方差系数的方法, 以 ELM 模型取代传统非线性规划方法进行系统状态评价, 大幅缩短了单次系统状态评价的时间, 因而加快了指标计算过程。

2 系统状态评估模型

本文电力系统网络模型采用交流潮流模型, 发电再调度模型则采用最优切负荷模型。为了进行系统状态评估, 对原目标函数进行修改, 原目标函数为经济调度下发电成本最小:

$$\min_{\Theta, V_m, p_g^i, q_g^i} \sum_{i=1}^{N_g} f_p^i(p_g^i) + f_q^i(q_g^i) \quad (13)$$

其中, Θ 、 V_m 、 p_g^i 、 q_g^i 分别为节点电压相角、电压幅值、第 i 台发电机有功功率输出、第 i 台发电机无功功率输出; $f_p^i(\cdot)$ 为第 i 台发电机组有功功率输出与成本的函数; $f_q^i(\cdot)$ 为第 i 台发电机组无功功率输出与成本的函数; N_g 为发电机数量。本文在求最优潮流时, 不计及无功市场作用, 认为 $f_q^i(\cdot) = 0$ 。为了使得目标函数等效为失负荷量最小, 取系统中 $f_p^i(p_g^i) = 0$, 定义负荷为可中断负荷, 可中断负荷视为有功注入为负的发电单元。

取可中断负荷 $f_p^i(p_g^i) = p_g^i$, 将目标函数式 (13) 转化为:

$$\min_{\Theta, V_m, p_g^i, q_g^i} \sum_{i=1}^{n_{dl}} p_g^i \quad (14)$$

其中, n_{dl} 为可中断负荷个数。上述目标函数转化为在约束条件内寻求最小的失负荷量。

3 算法快速可靠性评估流程

为了改善 MCS 的收敛速度, 本文在抽样环节引入 CE 构建元件的最优概率分布, 并以最优概率分布产生一定量的样本 (包括系统元件状态和失负荷情况) 作为 ELM 的样本进行训练, 然后以所训练的网络模型取代传统非线性规划方法进行系统状态评估, 进而加快评估速度。算法具体步骤如下。

a. 初始化 CE 参数。包括取样数量 N 、分位系数 $\rho^{[22]}$ 、平滑系数 α (α 值通常在 0.990~0.999 之间, 用于避免元件故障概率为 0 的情况^[23])、参数寻优迭代计数起始值 n_{iter} (取值 1); 令初始概率分布 $P_{n_{iter}}(\mathbf{X}) = P_u(\mathbf{X})$, $P_u(\mathbf{X})$ 为元件原始概率分布, 系统负荷 γ 取系统负荷峰值。

b. 根据概率分布 $P_{n_{iter}}(\mathbf{X})$ 产生系统状态 $\mathbf{X} = [\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_N]$, 并初步计算系统的指标 $S(\mathbf{X}_i)$ 。

$$S(\mathbf{X}_i) = [X_{i1}, \dots, X_{iN_g}] [C_1, \dots, C_{N_g}]^T \quad (15)$$

其中, C_i 为第 i 台发电机的发电容量。由于该指标未计及输电系统对可靠性的影响, 因此需进一步计算系统指标。对于状态 \mathbf{X}_i , 如果发生电压越限、线路过载风险, 则通过最优潮流对其进行调整, 若调整后仍发生切负荷现象 (设切负荷量 P_c), 则根据式 (16) 更新该状态指标; 反之, 该状态指标不变。

$$S(\mathbf{X}_i) = \gamma - P_c \quad (16)$$

c. 将指标 $S(\mathbf{X}_i)$ 升序排列为 $[S_1, S_2, \dots, S_N]$, 其中 $S_1 \leq S_2 \leq \dots \leq S_N$ 。

d. 若 $S_{\rho N} < \gamma$, 第 n_{iter} 次迭代时的系统负荷 $\gamma_{n_{iter}} = \gamma$; 否则, $\gamma_{n_{iter}} = S_{\rho N}$ 。根据式 (17) 计算失负荷指标 $R(\mathbf{X}_i)$; 然后由式 (4) 计算似然比。

$$R(\mathbf{X}_i) = \begin{cases} 1 & S(\mathbf{X}_i) < \gamma_{n_{\text{iter}}} \\ 0 & S(\mathbf{X}_i) \geq \gamma_{n_{\text{iter}}} \end{cases} \quad (17)$$

e. 由式(18)更新元件 j 概率分布参数 $P_{n_{\text{iter}}-j}(\mathbf{X})$ 。

$$P_{n_{\text{iter}}-j}(\mathbf{X}) = \alpha \left[1 - \frac{\sum_{i=1}^{N_s} F(\mathbf{X}_i) W(\mathbf{X}_i, P_u, P_{n_{\text{iter}}-1}) X_{ij}}{\sum_{i=1}^{N_s} F(\mathbf{X}_i) W(\mathbf{X}_i, P_u, P_{n_{\text{iter}}-1})} \right] + (1-\alpha) P_{n_{\text{iter}}-1-j} \quad (18)$$

其中, N_s 为 CE 优化取样数; $P_{n_{\text{iter}}-1}$ 为第 $n_{\text{iter}}-1$ 次 CE 优化迭代所构建的概率分布。

f. 若 $\gamma_{\text{iter}} = \gamma$, 此时 $P_{n_{\text{iter}}}(\mathbf{X})$ 即为最优概率分布, 转入步骤 g; 否则 $n_{\text{iter}} = n_{\text{iter}} + 1$, 并返回步骤 b。

g. 根据最优概率分布 $P_{n_{\text{iter}}}(\mathbf{X})$ 产生 N_1 个系统元件状态 \mathbf{X}_j , 并分别进行状态评估计算失负荷量 L_j , 形成 ELM 训练样本集 (\mathbf{X}_j, L_j) ($j=1, 2, \dots, N_1$)。

h. 确定隐层单元数量, 并随机初始化输入层和隐层的连接权重矩阵 \mathbf{W}_i 以及隐层神经元的偏置 b_i 。

i. 选择一个无限可微的函数作为隐层神经元的激活函数, 进而计算其输出矩阵 \mathbf{H} 。

j. 计算输出层的权值 $\hat{\beta} = \mathbf{H}^+ \mathbf{T}$ 。

k. 由最优概率分布 $P_{n_{\text{iter}}}(\mathbf{X})$ 抽样产生 N 个系统元件状态 $\mathbf{X} = [\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_N]$; 将 \mathbf{X} 作为网络的输入预测各状态的失负荷量 $\mathbf{L} = [L_1, L_2, \dots, L_N]$ 。

l. 根据系统状态 \mathbf{X} 和失负荷量 \mathbf{L} 计算可靠性指标系统失负荷概率 LOLP (Loss Of Load Probability) 和功率不足期望 EPNS (Expected Power Not Supplied), 直至指标收敛或达到抽样次数。

4 算例分析

以 IEEE RTS-79 作为算例, 该测试系统共有 24 个节点、38 条线路、32 台发电机、1 台调相机, 总装机容量 3 405 MW, 峰值负荷取 2 365 MW。测试算例计算时所采用的计算机配置参数为: CPU Core-i7 2 600、主频 3.4 GHz、系统类型 Window7 64 bit。

4.1 新算法评估结果

对 IEEE RTS-79 测试系统进行可靠性评估, 计算过程中, CE 优化阶段取分位数 $\rho = 0.05$, 平滑系数 $\alpha = 0.995$, 单次寻优取样数量 $N_s = 5\ 000$; ELM 模型训练阶段取隐层单元数 500, 训练样本数 5 000, 以 sigmoid 函数为激活函数。

通过计算系统 LOLP 和 EPNS 等指标 (LOLP 和 EPNS 均为系统性指标, 在系统状态评估过程中, 先由最优切负荷模型计算得到各个节点的失负荷情况, 进而通过统计各节点指标求得系统可靠性指标。在电力系统可靠性评估更加关注节点切负荷量的情况下, 可以只统计节点的切负荷量等指标, 其计算精

度与系统指标一致), 以 LOLP 方差系数 $\beta_{\text{LOLP}} < 5\%$ 或达到预期抽样次数作为收敛条件, 分析 MCS、CE 和 CE 与 ELM 结合算法 (以下简称 CE&ELM) 下测试系统的可靠性指标和计算效率, 各指标的迭代过程如图 2 所示。

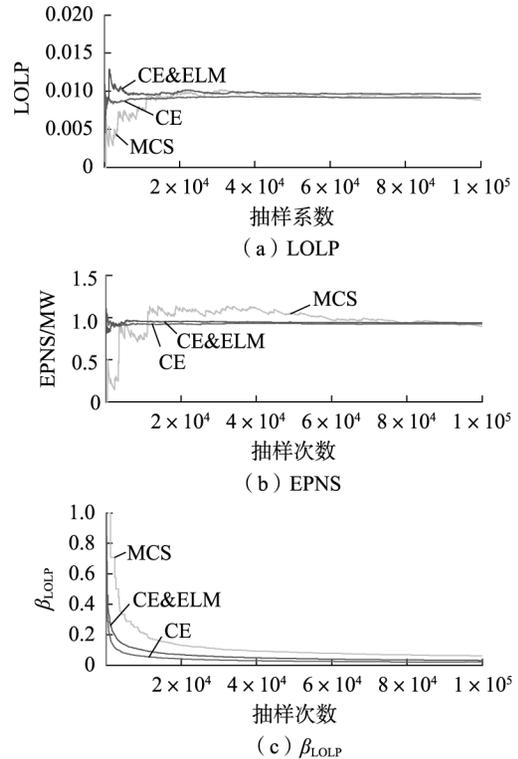


图 2 指标收敛过程

Fig.2 Convergence process of indexes

由图 2 指标迭代过程可知, CE&ELM 和 CE 均不同程度提高了 MCS 的可靠性评估效率。其中 MCS 过程由于达到预设抽样次数而终止指标迭代计算, 但其 LOLP 方差系数尚未达到收敛条件, 由此可见原始 MCS 在可靠性评价过程中计算效率极低, 相比之下, CE 和 CE&ELM 过程分别在 13 556 次和 37 274 次达到 LOLP 方差收敛条件, 这是由于 MCS 为完全随机化过程, 需要大量样本迭代才能使指标收敛, 而基于 CE 的重要抽样通过构建元件最优概率分布提高了失负荷事件的发生率, 减小了 LOLP 方差系数变化, 从而加快指标收敛速度。

对程序分块运行, 并统计各子程序用时。不同算法下测试系统的可靠性指标和计算总时间统计表 1 所示。

表 1 不同算法下可靠性指标和计算总时间

Table 1 Reliability indexes and total computing time of different algorithms

算法	LOLP	EPNS/MW	计算总时间/s
MCS	0.008 8	0.895 2	6 134.542
CE	0.009 1	0.916 3	2 061.372
CE&ELM	0.009 6	0.947 2	919.608

对各指标计算结果进行误差分析知,CE 重要抽样所计算的指标 LOLP 和 EPNS 较 MCS 的误差分别为 3.41% 和 2.36%;而 CE&ELM 的误差分别为 9.09% 和 5.81%, 相对较大, 其原因是 ELM 将原特征空间的数据随机映射至 ELM 特征空间, 势必会导致数据在 ELM 特征空间出现不易预测的非线性分布模型, 从而使得样本预测具有一定误差。

结合表 1 和各子程序分块时间统计知, 新算法在网络学习模型训练耗时 1.903 s, 样本预测耗时 2.852 s, ELM 阶段总耗时仅占计算总时间的 0.517%, 可见 ELM 具有极高的学习效率。根据不同算法下的计算总时间可知, CE 计算总时间较 MCS 减少约 66.40%; CE&ELM 迭代次数较 CE 更多, 但其计算总时间较 MCS 减少约 85.01%, 较 CE 减少约 55.39%, 这是由于 ELM 通过样本训练获得的网络模型进行系统状态评估, 大幅减少了单次系统状态评估的计算时间, 从而缩短了可靠性计算总时间, 由此可见 CE&ELM 计算效率极高。

4.2 与 SVM 算法对比

为了验证本文算法在计算效率的改进效果, 将其与 SVM 算法进行对比, 不同算法下 LOLP 的收敛过程和指标计算结果如图 3 和表 2 所示。

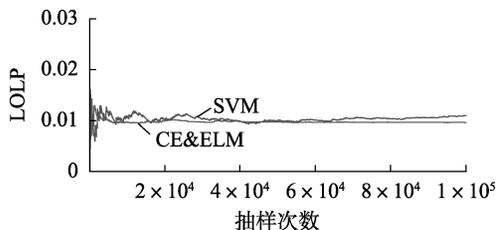


图 3 不同人工智能算法下 LOLP 收敛过程

Fig.3 Convergence process of LOLP for different artificial intelligence algorithms

表 2 不同人工智能算法计算结果

Table 2 Computing results of different artificial intelligence algorithms

算法	LOLP	EPNS/MW	计算总时间/s
SVM	0.010 1	0.951 5	4 462.153
CE&ELM	0.009 6	0.947 2	919.608

由图 3 中 LOLP 收敛过程和表 2 统计结果可知, 在一定的误差范围内, CE&ELM 的计算效率远高于 SVM。基于 SVM 构造的网络学习模型对正常状态和故障状态进行模式识别避免了正常状态的计算, 计算时间较 MCS 减少 27.26%, 但由于故障状态仍然需要调用 OPF 计算, 该过程耗时较长。

另一方面, 通过引入时间复杂度评价算法计算效率优劣, 基于 SVM 算法的时间复杂度为 $T(N) = O(N_{sv}^3)$, 其中 N_{sv} 为支持向量个数, 故算法的最坏运行时间为 $O(N^3)$ 。同理, 基于本文算法的时间复杂度为 $T(N) = O(N_{CE}^2 + N_{ELM}^2) = O(N^2)$, 其中 N_{CE} 为 CE

优化阶段样本数, N_{ELM} 为 ELM 样本训练阶段的隐藏层维数, 因此算法最坏运行时间为 $O(N^2)$ 。由此可见 CE&ELM 的计算效率优于 SVM。

4.3 误差分析

为分析 ELM 的预测精度, 以 CE 优化后的最优概率分布产生 6 000 个元件状态样本 $X = [X_1, X_2, \dots, X_{6000}]$, 并分别调用最优潮流模块计算状态失负荷量 $L = [L_1, L_2, \dots, L_{6000}]$; 取前 5 000 个系统状态样本 (X_j, L_j) 作为 ELM 模型训练的输入数据, 取后 1 000 个元件状态样本 X_j 作为测试数据进行状态预测; 通过对比预测值与实际值分析了 ELM 的预测误差。选取任意连续的 100 个样本作出其预测误差如图 4 所示。

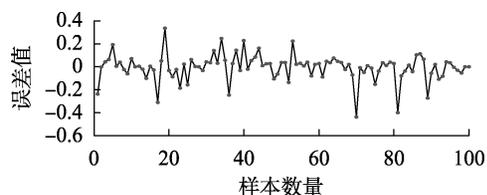


图 4 ELM 模型预测误差

Fig.4 Prediction error of ELM model

假设样本预测值与实际值的误差值在 $\pm 5\%$ 以内即为准确预测, 则通过统计上述样本的预测误差百分数求得 ELM 的预测准确度为 92.3%。

4.4 算法评价

本文所提算法对于不同规模和不同可靠性水平的系统改善效果也不同。当系统可靠性越高, MCS 需要越多样本迭代才能使指标收敛, 且对于结构越复杂、规模越大的系统, 单次状态评估的时间越长, 此时引入算法可以显著提高计算效率; 反之, 在网架结构薄弱、系统负载率高等情况下, 系统失负荷事件的发生率较高, 原始 MCS 在较少抽样次数下就能使得指标收敛, 引入算法可能会降低计算效率。而在现代电力系统中, 电气联系不断加强, 可靠性不断提高, MCS 计算效率越来越低, 因此本文算法有利于改善现代电力系统可靠性评估效率。

随着电网规模逐渐增大, 电网结构越来越复杂, 人工智能算法要达到预测精度所需要的样本势必会随系统规模增大而增加。由于本文 ELM 人工训练所使用的样本为 CE 重要抽样状态, CE 的本质是根据元件对指标的贡献程度强化“重要元件”的故障率, 同时弱化“非重要元件”的故障率, 故 CE 重要抽样的系统状态不仅对指标计算贡献大, 且相对均匀集中, 这使得 ELM 训练所需的样本容量大幅缩小, 而所谓的“重要元件”随系统规模增加进行“更迭”而不是线性增加, 故 ELM 训练样本的数量不会随着系统规模呈现线性增加。另一方面, 本文使用训练样本量的 10 倍规则法确定样本基数, 即训练样本数量是模型参数数量的 10 倍, ELM 模型参数数量决定指

标的计算精度,现有算法主要通过剪枝法和增量学习法确定 ELM 隐层节点数量^[24]。

综上所述,本文所提算法的指标计算精度虽略低于 CE 重要抽样,但其在重要抽样的基础上进一步加快 MCS 可靠性评估效率。在实际应用过程中,如多场景多方案的对比与决策、系统在线短时可靠性评估等方面,可以考虑引入高效的 CE 和 ELM 算法实现快速可靠性评估。

5 结论

本文在 MCS 过程中引入基于 CE 的重要抽样和 ELM 实现复杂电力系统的快速可靠性计算,对 IEEE RTS-79 测试系统进行可靠性评估,并与原始 MCS、CE 和 SVM 进行对比,得到以下结论:本文所提基于 CE 的重要抽样和 ELM 结合的算法分别从抽样阶段和状态评价阶段加快可靠性评估过程,其计算效率较原始 MCS 有显著提高;CE 优化过程通过构建元件的最优概率分布,在系统抽样环节实现重要抽样,即提高失负荷事件的发生率,从而减小方差变化,加快指标收敛速度,ELM 通过构建网络学习模型,在系统状态评估环节加快了单次评价速度,进而提高整个可靠性评估效率;本文算法对于电力系统实时、短期可靠性评估具有较大的实用价值。

参考文献:

- [1] 张籍,杜治,谢瀚阳,等. 基于不确定随机系统的新一代智能变电站可靠性分析[J]. 电力自动化设备,2017,37(9):210-217.
ZHANG Ji,DU Zhi,XIE Hanyang, et al. NGSS reliability analysis based on uncertain stochastic system[J]. Electric Power Automation Equipment,2017,37(9):210-217.
- [2] UBEDA J R,ALLAN R N. Sequential simulation applied to composite system reliability evaluation[J]. IEEE Proceedings-Generation, Transmission and Distribution,1992,139(2):81-86.
- [3] 杜江,郭瑞鹏,李传栋,等. 电力系统可靠性评估中的重要控制法[J]. 电力系统自动化,2015,39(5):69-74.
DU Jiang,GUO Ruipeng,LI Chuandong, et al. An importance-control method for power system reliability evaluation[J]. Automation of Electric Power Systems,2015,39(5):69-74.
- [4] 许鹏程,陈启,刘文霞,等. 引入交叉熵与动态故障集的含风电大电网可靠性评估[J]. 电力系统自动化,2016,40(13):28-34.
XU Pengcheng,CHEN Qi,LIU Wenxia, et al. Reliability evaluation in composite power system considering wind farms based on the combination of cross-entropy and dynamic fault set[J]. Automation of Electric Power Systems,2016,40(13):28-34.
- [5] 张巍峰,车延博,刘阳升. 电力系统可靠性评估中的改进拉丁超立方抽样方法[J]. 电力系统自动化,2015,39(4):52-57.
ZHANG Weifeng,CHE Yanbo,LIU Yangsheng. Improved Latin hypercube sampling method for reliability evaluation of power systems[J]. Automation of Electric Power Systems,2015,39(4):52-57.
- [6] GREEN R C,WANG L,ALAM M. Composite power system reliability evaluation using support vector machines on a multicore platform [C]//The 2011 International Joint Conference on Neural Networks (IJCNN). San Jose,CA,USA:IEEE,2011:2586-2592.
- [7] SINGH C,WANG L. Role of artificial intelligence in the reliability evaluation of electric power systems[J]. Turkish Journal of Electrical Engineering & Computer Sciences,2008,16(3):189-200.
- [8] 王景辰,李孝全,杨洋,等. 基于蒙特卡洛法和最小二乘支持向量机的复杂电力系统可靠性评估[J]. 华东电力,2013,41(5):1001-1004.
WANG Jingchen,LI Xiaoquan,YANG Yang, et al. Reliability evaluation of complex power system based on Monte Carlo simulation and least squares support vector machine[J]. East China Electric Power,2013,41(5):1001-1004.
- [9] 朱清清,严正,贾燕冰,等. 输电线路运行可靠性预测[J]. 电力系统自动化,2010,34(24):18-22.
ZHU Qingqing,YAN Zheng,JIA Yanbing, et al. Prediction of transmission operating reliability[J]. Automation of Electric power Systems,2010,34(24):18-22.
- [10] 成锐,刘文霞,金秋龙,等. 基于分布估计和智能存储的复杂电网可靠性评估方法[J]. 中国电机工程学报,2017,37(19):5541-5548,5831.
CHENG Rui,LIU Wenxia,JIN Qiulong, et al. Reliability evaluation in composite power system based on estimation of distribution algorithm and intelligent storage[J]. Proceedings of the CSEE,2017,37(19):5541-5548,5831.
- [11] 叶圣永,王晓茹,刘志刚,等. 基于受扰严重机组特征及机器学习方法的电力系统暂态稳定评估[J]. 中国电机工程学报,2011,31(1):46-51.
YE Yongsheng,WANG Xiaoru,LIU Zhigang, et al. Power system transient stability assessment based on severely disturbed generator attributes and machine learning method [J]. Proceedings of the CSEE,2011,31(1):46-51.
- [12] 马骞,杨以涵,刘文颖,等. 多输入特征融合的组合支持向量机电力系统暂态稳定评估[J]. 中国电机工程学报,2005,25(6):17-23.
MA Qian,YANG Yihan,LIU Wenyong, et al. Power system transient stability assessment with combined SVM method mixing multiple input features[J]. Proceedings of the CSEE,2005,25(6):17-23.
- [13] 陈民铎,朱博,徐瑞林,等. 基于混合智能技术的微电网剩余负荷超短期预测[J]. 电力自动化设备,2012,32(5):13-18.
CHEN Minyue,ZHU Bo,XU Ruilin, et al. Ultra-short-term forecasting of microgrid surplus load based on hybrid intelligence techniques [J]. Electric Power Automation Equipment,2012,32(5):13-18.
- [14] 钟波,赵渊,周家启. 基于粗神经网络的电力系统可靠性评估方法[J]. 重庆大学学报(自然科学版),2005,28(7):38-42.
ZHONG Bo,ZHAO Yuan,ZHOU Jiaqi. Methods of power systems reliability assessment based on rough neural network[J]. Journal of Chongqing University(Natural Sciences),2005,28(7):38-42.
- [15] 王韶,周家启. 基于函数型连接神经网络的发输电系统可靠性评估研究[J]. 中国电机工程学报,2004,24(9):142-146.
WANG Shao,ZHOU Jiaqi. Study on reliability assessment of composite generation and transmission system based on functioned link neural network[J]. Proceedings of the CSEE,2004,24(9):142-146.
- [16] HUANG G B,ZHOU H,DING X, et al. Extreme learning machine for regression and multiclass classification [J]. IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics),2012,42(2):513-529.
- [17] 王保义,赵硕,张少敏. 基于云计算和极限学习机的分布式电力负荷预测算法[J]. 电网技术,2014,38(2):526-531.
WANG Baoyi,ZHAO Shuo,ZHANG Shaomin. A distributed load forecasting algorithm based on cloud computing and extreme learning machine[J]. Power System Technology,2014,38(2):526-531.

- [18] ZIO E. Practical applications of advanced Monte Carlo simulation techniques for system failure probability estimation[M]. London, UK:Springer,2013:157-179.
- [19] 王越,郭创新,文云峰,等.一种三段式序贯交叉熵重采样方法及其在电力系统短期可靠性评估中的应用[J].中国电机工程学报,2013,33(28):94-100.
WANG Yue, GUO Chuangxin, WEN Yunfeng, et al. A three-stage sequential cross-entropy importance sampling method and its application in composite power system short-term reliability evaluation[J]. Proceedings of the CSEE, 2013, 33(28):94-100.
- [20] GONZÁLEZ-FERNÁNDEZ R A, DA SILVA A M L, RESENDE L C, et al. Composite systems reliability evaluation based on Monte Carlo simulation and cross-entropy methods[J]. IEEE Transactions on Power Systems, 2013, 28(4):4598-4606.
- [21] HUANG G B, WANG D H, LAN Y. Extreme learning machines: a survey[J]. International Journal of Machine Learning and Cybernetics, 2011, 2(2):107-122.
- [22] RUBINSTEIN R Y, KROESE D P. The cross-entropy method: a unified approach to combinatorial optimization, Monte-Carlo simulation and machine learning[M]. Memphis, Tennessee, USA: Springer Science & Business Media, 2013.
- [23] LUO X, SINGH C, PATTON A D. Power system reliability evaluation using learning vector quantization and Monte Carlo simulation[J]. Electric Power Systems Research, 2003, 66(2):163-169.
- [24] 徐志鑫. 极限学习机隐含层节点选择算法研究[D]. 杭州: 浙江大学, 2017.
XU Zhixin. Research on the selection of hidden layer nodes for extreme learning machine[D]. Hangzhou: Zhejiang University, 2017.

作者简介:



许鹏程

许鹏程(1990—),男,福建泉州人,硕士,主要研究方向为电力系统可靠性、数据结构(**E-mail**:ncepuxpc@163.com);

刘文霞(1967—),女,北京人,教授,博士研究生导师,博士,主要研究方向为电力系统风险及可靠性评估、经济调度(**E-mail**:liuwenxia001@163.com);

陈启(1990—),男,湖北荆门人,硕士,主要研究方向为电力系统可靠性评估方法(**E-mail**:qichantd@163.com)。

Reliability evaluation of large power system based on combination of important sampling and extreme learning machine

XU Pengcheng¹, LIU Wenxia², CHEN Qi³, ZHANG Hao¹

(1. Fuzhou Electric Power Bureau of State Grid Fujian Electric Power Company, Fuzhou 350009, China;

2. State Key Laboratory of Alternate Electrical Power System with Renewable Energy Source, North China Electric Power University, Beijing 102206, China;

3. Ningbo Electric Power Bureau of State Grid Zhejiang Electric Power Company, Ningbo 315012, China)

Abstract: Due to many uncertainty factors and large-scale power grid, the traditional MCS (Monte Carlo Simulation) cannot meet the requirements of real-time and high efficiency in the reliability evaluation of complex power system. A reliability evaluation algorithm with the combination of CE (Cross-Entropy) based important sampling and ELM (Extreme Learning Machine) is proposed. On one hand, CE is introduced in the system sampling step to construct the equipment optimal probability distribution, decrease the variance variation and speed up the index convergence. On the other hand, ELM is adopted for supervised learning of the state samples from important sampling, and the traditional nonlinear programming method is replaced by the constructed network learning model for state evaluation, so as to improve the efficiency of single evaluation and realize fast reliability evaluation. Reliability evaluation is carried out in IEEE RTS-79 system, and comparison with the results of traditional MCS and CE important sampling shows that the proposed algorithm is rational and effective in a certain error range, and its computational efficiency is significantly higher than that of the traditional MCS and CE.

Key words: reliability evaluation; important sampling; cross-entropy; extreme learning machine; supervised learning