

引用格式:刘颂凯,曹俊,苏攀,等.基于MWMOTE和SSA-KELM的电力系统静态电压稳定评估[J].电力科学与技术学报,2026,41(1):13-22.

Citation: LIU Songkai, CAO Jun, SU Pan, et al. Static voltage stability assessment of power systems based on MWMOTE and SSA-KELM[J]. Journal of Electric Power Science and Technology, 2026, 41(1): 13-22.

基于MWMOTE和SSA-KELM的电力系统 静态电压稳定评估

刘颂凯^{1,2}, 曹俊^{1,2}, 苏攀^{1,2}, 高坤³, 吴宇恒^{1,2}, 万明^{1,2}, 艾迪^{1,2}

(1. 三峡大学电气与新能源学院, 湖北宜昌 443002; 2. 新能源微电网湖北省协同创新中心, 湖北宜昌 443002;

3. 国网湖南省电力有限公司常德供电分公司, 湖南常德 415130)

摘要: 基于数据驱动的电力系统静态电压稳定评估方法通常存在初始数据样本类别不平衡问题, 导致数据驱动评估模型的性能受到很大的影响。为此, 提出一种基于带多数类权重的少数类过采样技术 (majority weighted minority oversampling technique, MWMOTE) 和麻雀搜索算法优化核极限学习机 (sparrow search algorithm-kernel extreme learning machine, SSA-KELM) 的电力系统静态电压稳定评估方法。首先, 利用MWMOTE解决样本类别不平衡问题, 增加样本多样性; 然后, 使用SSA优化KELM模型参数, 构建基于SSA-KELM的电力系统静态电压稳定评估模型; 最后, 在新英格兰 10 机 39 节点系统上进行验证。测试结果表明, 所提方法不仅能够有效应对样本类别不平衡问题, 还具有好的评估准确率和泛化能力。

关键词: 样本类别不平衡; 静态电压稳定评估; 带多数类权重的少数类过采样技术; 麻雀搜索算法; 核极限学习机

DOI: 10.19781/j.issn.1673-9140.2026.01.002 中图分类号: TM712 文章编号: 1673-9140(2026)01-0013-10

Static voltage stability assessment of power systems based on MWMOTE and SSA-KELM

LIU Songkai^{1,2}, CAO Jun^{1,2}, SU Pan^{1,2}, GAO Kun³, WU Yuheng^{1,2}, WAN Ming^{1,2}, AI Di^{1,2}

(1. College of Electrical Engineering and New Energy, China Three Gorges University, Yichang 443002, China; 2. Hubei Provincial

Collaborative Innovation Center for New Energy Microgrid, Yichang 443002, China; 3. Changde Power Supply Branch,

State Grid Hunan Electric Power Co., Ltd., Changde 415130, China)

Abstract: The static voltage stability assessment method of a power system based on data drive usually has the problem of an unbalanced sample category in the initial data, which makes the performance of the data-driven assessment model greatly affected. Therefore, a static voltage stability assessment method of a power system is proposed based on the majority weighted minority oversampling technique (MWMOTE) and sparrow search algorithm-kernel extreme learning machine (SSA-KELM). First, MWMOTE is used to solve the problem of an unbalanced sample category and increase sample diversity. Then, the KELM model parameters are optimized by using SSA, and the static voltage stability assessment model of the power system based on SSA-KELM is constructed. Finally, the validation is carried out on a 10-machine 39-bus system of New England, and the test results show that the proposed method can effectively deal with the problem of unbalanced sample categories with good assessment accuracy and generalization ability.

Key words: unbalanced sample category; static voltage stability assessment; majority weighted minority oversampling technique; sparrow search algorithm; kernel extreme learning machine

收稿日期: 2025-01-20; 修回日期: 2025-09-06

基金项目: 国家自然科学基金(52407118)

通信作者: 苏攀(1985—), 男, 硕士, 主要从事输电线路工程方面的研究; E-mail: supan12@163.com

随着电力系统的广域互联和可再生能源的不断接入,电力系统的规模越来越大,结构日益复杂,系统运行特性日益多变,电力系统的安全稳定运行面临着巨大的挑战^[1-2]。电压失稳已经成为全球多次大规模停电事故的主要原因之一。这不仅造成了重大的经济损失,而且对人们的生活和工业生产造成了不可预测的影响。因此,亟需一种能够快速、准确识别当前运行状态是否容易发生电压崩溃的评估工具,以便系统操作人员采取相应的控制措施,防止可能发生的电压崩溃。

传统的静态电压稳定分析方法,如连续潮流法^[3]、奇异值分解法^[4]和非线性规划法^[5]等,由于其计算复杂、耗时较长等缺陷,难以满足现代电力系统的在线监测需求。随着相量测量单元(phasor measurement unit, PMU)在电网中的普及度不断提升^[6],基于PMU的广域测量系统所提供的海量测量数据为数据驱动方法的在线应用提供了坚实的数据基础^[7]。相比于传统数据采集与监控系统的异步性和速度滞后,PMU采集的同步数据显著提高了响应速度和决策效率^[8]。

近年来,许多数据驱动方法被成功地应用于电力系统静态电压稳定分析。文献[9]在已有电压稳定性指标的基础上进行了数学等值改造,提出了两类新的电压稳定性指标,包括弱模式电压稳定裕度指标与弱模式电压稳定差异指标,分别从弱模式下系统稳定程度的平均状况与弱模式之间的稳定差异程度两个方面对系统的电压稳定状况进行了全面评估。文献[10]提出了一种基于梯度提升决策树的电压稳定裕度在线监测方法,该方法通过模拟负荷变化求解最优潮流模型,得到各发电机出力状态及对应的电压稳定裕度,进而形成离线运行点数据库,并在在线阶段对梯度提升决策树进行训练,实现电压稳定裕度的实时评估。文献[11]从“源-网-荷”统一角度构建了电网电磁功率传递与节点电压相量各分量属性的联系,进而提出了利用差分稳定系数指标来评估电网能量稳定态势,并融合两种指标,提出了基于电压量测信息的电网静态稳定在线评估方法。文献[12]构建了电压稳定非线性规划模型,采用机会约束引入随机变量,利用拉丁超立方重点采样法构建样本空间,并使用内点法计算系统临界功率的概率分布。文献[13]将静态电压稳定评估问题定义为回归问题,构建了人工神经网络模型进行在线评估。文献[14]使用最大相关最小冗余准则和Shapley值进行特征选择,构建了一个

利用梯度提升分段线性回归树的静态电压稳定评估模型,并通过迁移成分分析法对模型进行更新。文献[15]应用集成多个决策树的随机森林分类器,自动进行特征选择,实现了静态电压稳定评估。文献[16]使用支持向量机处理高维非线性样本,保证了静态电压稳定评估模型的准确性和泛化能力。虽然上述方法取得了一定的效果,但未考虑电力系统静态电压稳定评估研究中可能出现的样本不平衡问题。在现代电力系统中,由于失稳情况发生的概率较低,在进行静态电压稳定性评估时,稳定样本远多于失稳样本,形成了显著的样本类别不平衡现象。这种不平衡会导致训练出的评估模型对失稳样本的信息学习不足,从而降低了对少数失稳样本的识别能力,导致漏判率上升^[17]。

针对上述不足,本文提出了一种基于带多数类权重的少数类过采样技术(majority weighted minority oversampling technique, MWMOTE)和麻雀搜索算法优化核极限学习机(sparrow search algorithm-kernel extreme learning machine, SSA-KELM)的电力系统静态电压稳定评估方法。该方法首先利用MWMOTE处理样本类别不平衡问题,使得失稳样本与稳定样本在数量上达到相对均衡;然后利用KELM构建静态电压稳定模型,并使用SSA对其参数进行寻优。最后,在新英格兰10机39节点系统上进行算例分析,验证了该方法的有效性。

1 MWMOTE原理

针对样本类别不平衡问题,本文使用MWMOTE算法^[17]对不平衡数据集进行过采样处理,该方法能使失稳样本与稳定样本的数量达到均衡,并且保证了新合成的少数类失稳样本所包含信息的质量,降低了噪声对新合成样本的不良影响,其示意图如图1所示。




图1 MWMOTE

Figure 1 MWMOTE

MWMOTE通过融合少数类样本密度分布与分类边界信息确定关键样本权重,其数学定义为

$$\omega_d^{(i)} = \frac{1}{K} \sum_{k=1}^K \exp\left(-\frac{\|x_i - x_k\|^2}{2\sigma_1^2}\right) \quad (1)$$

$$\omega_b^{(i)} = \frac{1}{N_b} \sum_{j=1}^{N_b} \frac{1}{\|x_i - x_j\| + \epsilon} \quad (2)$$

$$W^{(i)} = \alpha \cdot \frac{\omega_d^{(i)}}{\max(\omega_d^{(i)})} + (1 - \alpha) \cdot \frac{\omega_b^{(i)}}{\max(\omega_b^{(i)})} \quad (3)$$

式中, $\omega_d^{(i)}$ 为密度权重; x_i 为第 i 个少数类样本; x_k 为其 K 个邻近样本, $K=5$; σ_1 为高斯核带宽; $\omega_b^{(i)}$ 为边界权重; N_b 为多数类样本中处于分类边界的样本数; x_j 为多数类样本中位于分类边界区域的第 j 个样本; ϵ 为防止分母为零的小常数; $W^{(i)}$ 为综合权重; α 为平衡因子, $\alpha=0.7$ 。

定义少数类失稳样本集为 D_{\min} , 多数类稳定样本集为 D_{maj} , 需合成的少数类失稳样本数量为 N 。算法的具体步骤如下。

1) 对于任一少数类失稳样本 $x_i \in D_{\min}$, 基于欧式距离计算其 k_1 个邻近样本, 若其中少数类失稳样本数量为 0, 则定义该样本为噪声并剔除该样本。定义去除噪声样本后的少数类失稳样本集为 D_{minf} 。

2) 对于任一少数类失稳样本 $x_i \in D_{\text{minf}}$, 寻找其 k_2 个邻近多数类样本, 构成多数类稳定样本集 $N_{\text{maj}}(x_i)$, 获取多数类稳定边界样本集为

$$D_{\text{bmaj}} = \bigcup_{x_i \in D_{\text{minf}}} N_{\text{maj}}(x_i) \quad (4)$$

3) 对于任一多数类稳定边界样本 $y_i \in D_{\text{bmaj}}$, 寻找其 k_3 个邻近少数类样本, 构成少数类失稳样本集 $N_{\text{min}}(y_i)$, 获取少数类失稳样本信息集为

$$D_{\text{imin}} = \bigcup_{y_i \in D_{\text{bmaj}}} N_{\text{min}}(y_i) \quad (5)$$

4) 对于每个样本 $x_i \in D_{\text{imin}}, y_i \in D_{\text{bmaj}}$, 根据样本所在位置距离和密度因素计算信息权重 $I_w(y_i, x_i)$, 距离多数类样本越近, 密度越低, 越容易被选择。

5) 对于每个样本 $x_i \in D_{\text{imin}}$, 计算其选择权重为

$$S_w(x_i) = \sum_{y_i \in D_{\text{bmaj}}} I_w(y_i, x_i) \quad (6)$$

6) 对每个样本 $x_i \in D_{\text{imin}}$ 的选择权重进行归一化处理, 计算其选择概率 $S_p(x_i)$ 。

7) 对 D_{imin} 进行聚类分析得到 M 个类簇。

8) 根据选择概率, 将 D_{imin} 中的每个少数类失稳样本 x 分配到 M 个簇中, 并从这些簇中随机选择多数类的稳定样本 y , 以合成新的样本为

$$s = x + \lambda(y - x) \quad (7)$$

式中, λ 为 $[0, 1]$ 范围内的随机数。

重复步骤 8), 直至合成 N 个少数类失稳样本。

2 KELM 算法及其优化

2.1 KELM 原理

ELM 是一种单隐层前馈神经网络, 具有训练速度快、泛化性能良好等优势^[18-20], 网络结构如图 2 所示。KELM 是一种改进的极限学习机算法, 通过引入核函数来增强模型性能, 既保留了 ELM 的快速训练和良好泛化能力, 又提高了预测准确性和稳定性。




图 2 ELM 网络结构

Figure 2 Network structure of ELM

ELM 的学习目标函数为

$$f(x) = h(x)\beta = H\beta = L \quad (8)$$

式中, x 为输入向量; $h(x)$ 、 H 均为隐层节点的输出特征向量; β 为权值向量; L 为预测目标值向量。其中, β 的计算方法为

$$\beta = H^*L \quad (9)$$

式中, H^* 为 H 的广义逆矩阵。

由于 β 的求解过程同时考虑了最小化训练误差和最小化输出权重的范数, 为此, 在优化阶段引入了正则化参数 C 和单位矩阵 I 。输出权重 β 可表示为

$$\beta = H^*(HH^* + \frac{I}{C})^{-1}L \quad (10)$$

为了获得更为稳定的预测输出, 通过引入核函数到 ELM 中, 核矩阵 Ω_{ELM} 可以定义为

$$\Omega_{\text{ELM}} = HH^* = h(x_i)h(x_j) = K(x_i, x_j) \quad (11)$$

式中, $K(x_i, x_j)$ 为核函数, 本文中用的是径向基 (radial basis function, RBF) 核函数, 定义为

$$K(x_i, x_j) = \exp(-(\mu - v^2/\sigma)) \quad (12)$$

则式 (8) 可表示为

$$f(x) = [K(x, x_1); K(x, x_2); \dots; K(x, x_n)] \left(\frac{I}{C} + \Omega_{\text{ELM}} \right)^{-1}L \quad (13)$$

通过引入核函数, KELM 能够以稳定的核函数矩阵替代随机的隐层输出矩阵, 从而提高 ELM 的泛化能力和稳定性。KELM 模型的输入层维度由

特征提取模块决定,输入层为4维,对应与电力系统电压稳定有关的4个电气量,具体输入特征将在文3.2详细介绍。输出层为1维标量,对应电力系统静态电压稳定评估结果。网络通过RBF核函数将输入特征映射至高维空间,并基于最小二乘解直接计算输出权重,避免传统迭代优化过程。然而,KELM的预测性能容易受正则化参数 C 和核函数参数 σ 的影响。因此,本文利用SSA对这两个参数进行优化。

2.2 SSA原理

SSA是一种新兴的群体智能优化算法^[21],灵感来自麻雀的觅食行为:①作为发现者,搜索食物;②作为跟随者,跟随发现者觅食;③作为警戒者,侦查预警,有危险则放弃食物。假设在一个 d 维空间中存在 n 个麻雀个体,组成的种群可以表示为

$$X = \begin{bmatrix} x_1^1 & x_1^2 & \cdots & x_1^d \\ x_2^1 & x_2^2 & \cdots & x_2^d \\ \vdots & \vdots & \ddots & \vdots \\ x_n^1 & x_n^2 & \cdots & x_n^d \end{bmatrix} \quad (14)$$

所有个体的适应度值可以定义为

$$F_x = \begin{bmatrix} f([x_1^1 \ x_1^2 \ \cdots \ x_1^d]) \\ f([x_2^1 \ x_2^2 \ \cdots \ x_2^d]) \\ \vdots \\ f([x_n^1 \ x_n^2 \ \cdots \ x_n^d]) \end{bmatrix} \quad (15)$$

式中, $f(\cdot)$ 为每个个体的适应度值。

对于发现者,若其个体适应度值较高,则在觅食过程中优先得到食物,其位置更新规则为

$$X_{i,j}^{t+1} = \begin{cases} X_{i,j}^t \exp(-\frac{i}{\alpha T}), & R_2 < S_T \\ X_{i,j}^t + QL_1, & R_2 \geq S_T \end{cases} \quad (16)$$

式中, $\alpha \in (0, 1]$ 为随机数; $X_{i,j}$ 为第 i 个个体在第 j 维中的位置信息; $R_2 \in [0, 1]$ 为预警值; T 为最大迭代次数; Q 为随机数,且满足正态分布; t 为当前迭代次数; $S_T \in [0.5, 1]$ 为安全值; L_1 表示大小为 $1 \times d$ 的矩阵,其中元素均为1。

对于跟随者,其位置更新规则为

$$X_{i,j}^{t+1} = \begin{cases} Q \exp(\frac{X_{\text{worst}}^t - X_{i,j}^t}{\alpha \cdot T}), & i > \frac{n}{2} \\ X_p^{t+1} + |X_{i,j}^t - X_p^{t+1}| A^+ L_1, & i \leq \frac{n}{2} \end{cases} \quad (17)$$

式中, X_{worst} 、 X_p 分别为当前全局最差位置和种群个体中发现者的最优位置; A 为大小为 $1 \times d$ 的矩阵,其中元素随机为1或-1,且满足 $A^+ = A^T(AA^T)^{-1}$ 。

警戒者的数量通常占麻雀总数的10%~20%,

其位置更新规则为

$$X_{i,j}^{t+1} = \begin{cases} X_{\text{best}}^t + \beta_1 |X_{i,j}^t - X_{\text{best}}^t|, & f_i > f_g \\ X_{i,j}^t + K_1 (\frac{|X_{i,j}^t - X_{\text{worst}}^t|}{(f_i - f_w) + \epsilon}), & f_i = f_g \end{cases} \quad (18)$$

式中, ϵ 为用来避免分母为零的一个常数; f_i 为第 i 个个体的适应度值; X_{best} 为当前全局最优位置; β_1 为步长控制参数; f_g 、 f_w 分别为当前全局适应度值的最佳值和最差值; $K_1 \in [-1, 1]$ 为随机数。

算法的终止条件基于预设的最大迭代次数,在本文中最大迭代次数设置为200次,当迭代次数达到最大迭代次数时,算法终止并输出当前最优解。

2.3 KELM的优化步骤

SSA通过不断搜索和更新找出全局的最优位置 X_{best} ,并将最优位置的正则化参数 C 和核函数参数 σ 作为KELM的参数。SSA优化KELM流程如图3所示。KELM的具体优化步骤如下:

步骤1:设置种群数量 n ,算法的最大迭代次数 T ,发现者和警戒者所占的比例;

步骤2:计算每个麻雀个体适应度值并排序;

步骤3:通过式(13)~(15)的计算来对警戒者、跟随者和发现者三者的位置进行不断更新;

步骤4:重新计算每只麻雀的适应度值,保留更优的适应度值,继续更新;

步骤5:判断是否达到最大迭代次数,若没有,则重复步骤2~5;反之,则终止运行;

步骤6:得到最优位置 X_{best} ,将最优位置的参数 C 和 σ 作为KELM的参数。

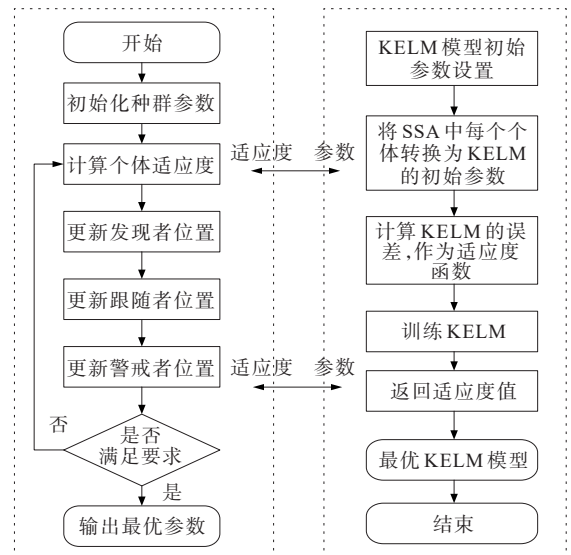


图3 SSA优化KELM流程

Figure 3 Process of KELM optimization by using SSA

3 基于 SSA-KELM 的静态电压稳定评估模型

3.1 电压稳定裕度指标

在电力系统的静态电压稳定性分析中, $P-U$ 曲线常被作为安全分析的工具^[22], 能清晰地展示系统电压随负荷变化的动态过程, 如图 4 所示。图 4 中, P_0 为系统运行点 a 的负荷有功功率, P_{\max} 为电压崩溃点 b 的最大负荷有功功率, 可以得到负荷的有功裕度为

$$\Delta P = P_{\max} - P_0 \quad (19)$$

电压稳定裕度定义为

$$K_p = \frac{P_{\max} - P_0}{P_0} \times 100\% \quad (20)$$

根据《电力系统电压稳定评价导则》可知, 在 $N-1$ 故障下, 电力系统的电压稳定裕度应大于 5%。因此, 通过观察 K_p 的值, 可以时刻监测系统运行的稳定水平。




图 4 P-V 曲线

Figure 4 P-V curve

3.2 输入特征构建

基于数据驱动算法构造的静态电压稳定评估模型的实质是在离线阶段利用大量的样本对所使用的评估模型进行训练, 寻找输入特征与电压稳定裕度之间的映射关系, 以用于在线应用。因此, 输入特征的合理选择不仅可以提高静态电压稳定评估模型的准确率, 还能在一定程度上提高模型的运算效率。本文选取一些常见的、与电力系统电压稳定有关的电气量作为输入特征, 包括发电机的无功功率与有功功率、节点电压相角与幅值。

3.3 静态电压稳定评估流程

基于 SSA-KELM 的电力系统静态电压稳定评估流程如图 5 所示, 包含离线和在线两个阶段: 离线训练阶段, 包括数据生成、数据过采样、模型

训练及优化和模型性能评估 4 个环节; 在线应用阶段, 通过将电力系统的实时运行数据输入离线训练好的模型中, 从而实现对系统稳定状况的实时监测。

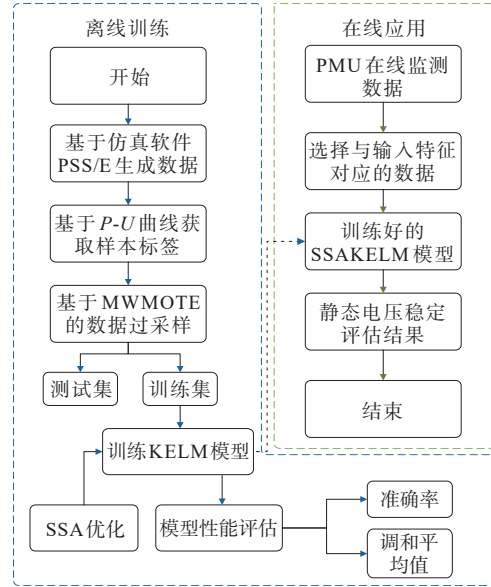


图 5 静态电压稳定评估流程

Figure 5 Assessment process for static voltage stability

3.4 模型评价指标

为测试 SSA-KELM 模型的评估效果, 本文使用准确率 A_{cc} 、精确率 P_{re} 、召回率 R 与精确率和召回率的调和平均值 F_1 作为评价指标。其中, $A_{cc} \in (0, 1)$, A_{cc} 越接近 1, 模型的评估性能越好; $F_1 \in (0, 1)$, F_1 值越接近 1, 同样表明模型的评估性能越好。

表 1 为电力系统静态电压稳定评估的混淆矩阵, A_{cc} 、 P_{re} 、 R 和 F_1 的计算公式^[23] 分别为

$$A_{cc} = \frac{T_p + T_n}{T_p + F_p + F_n + T_n} \quad (21)$$

$$P_{re} = \frac{T_p}{T_p + F_p} \quad (22)$$

$$R = \frac{T_p}{T_p + F_n} \quad (23)$$

$$F_1 = \frac{2T_p}{2T_p + F_p + F_n} \quad (24)$$

表 1 混淆矩阵

Table 1 Confusion matrix

评估结果	实际结果	
	稳定	失稳
稳定	T_p	F_p
失稳	F_n	T_n

式中, F_P 、 F_N 分别为错误评估为失稳的样本数量和错误评估为稳定的样本数量; T_P 、 T_N 分别代表正确评估的失稳样本和稳定样本的数量。

4 算例分析

4.1 数据生成和参数设置

为验证本文所提基于 MWMOTE 和 SSA-KELM 的电力系统静态电压稳定评估方法的有效性, 在如图 6 所示的新英格兰 10 机 39 节点系统上进行算例分析。

为了生成足够的样本数据, 本文通过 PSS/E 仿真软件对线路和发电机进行多种 $N-k$ 场景仿真, 并在每种场景对应的网络结构下进行 $P-V$ 曲线分析。首先, 以负荷功率和发电机有功出力基准值为基础, 在其 70%~130% 的范围内随机取值, 对系统进行初始化。然后, 保持负荷功率因数不变, 设置连续潮流的负荷增长方向为全网中负荷以相同百分比增加。在此过程中, 不考虑发电机的无功限制, 增长的负荷有功功率由所有发电机按初始出力比例共同承担。最终, 通过仿真生成了 3 600 个初始样本。其中, 稳定样本与失稳样本的比例为 5:1, 经过 MWMOTE 过采样后, 稳定样本与失稳样本数量基本一致。随机选择 70% 的样本对评估模型进行训练, 剩余 30% 的样本作为测试集对评估模型进行测试。

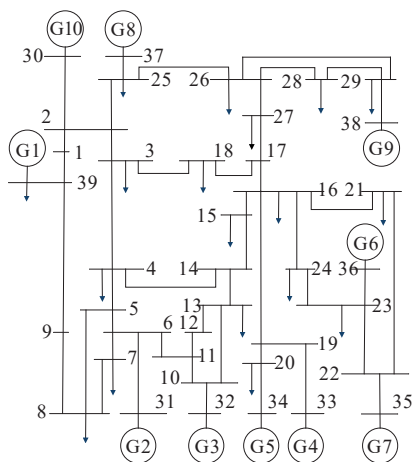


图 6 新英格兰 10 机 39 节点系统

Figure 6 10-machine 39-bus system of New England

在本文中, KELM 的参数设置如下^[24]: 核函数为 RBF, 隐层的激活函数为 Sigmoid 函数, 隐层节点数设置为 200, 初始正则化参数 C 和核参数 σ 分别设置为 1 和 0.1。SSA 的参数设置如下: 种群规模设置为 50, 最大迭代次数为 200, 发现者和警戒者的数量

均占种群总数的 20%, 预警值 R_2 设置为 0.8。

4.2 过采样方法对比

为测试样本不平衡问题对评估模型的影响, 进一步验证本文所提 MWMOTE 算法对样本不平衡问题的处理效果, 突出其有效性和优越性, 在模型训练前, 分别使用合成少数类过采样 (synthetic minority oversampling technique, SMOTE)、边界合成少数类过采样 (borderline-SMOTE, B-SMOTE)、自适应综合采样 (adaptive synthetic sampling, ADASYN) 随机过采样 (random oversampling, ROS) 和 MWMOTE 对初始样本进行处理, 将处理后的数据用于训练和测试 SSA-KELM 模型, 测试结果如表 2 所示。可知, 如果不针对不平衡数据进行处理, SSA-KELM 模型的 A_{cc} 、 P_{re} 、 R 和 F_1 均较低, 模型的评估结果可信度不足, 难以在线应用。使用过采样算法处理不平衡数据后, 评估模型的 A_{cc} 、 P_{re} 、 R 和 F_1 值均显著上升, 模型性能显著提升。此外, 与其他过采样方法相比, 本文所使用的 MWMOTE 算法对评估模型性能的提升作用最大。这是因为 ROS 只是简单地在样本集中复制失稳样本, 容易导致评估模型过拟合; SMOTE 在不了解邻近失稳样本的情况下, 通过线性插值盲目地为每个失稳样本合成新样本, 容易导致类重叠; B-SMOTE 只对处于稳定边界周围的失稳样本进行采样, 忽略了其他失稳样本的信息, 降低了评估模型的泛化能力; ADASYN 合成样本的质量很容易受到噪声的影响。而 MWMOTE 有效地避免了上述不足, 因此所展现的实验效果最好。

表 2 不同过采样方法的性能测试结果
Table 2 Performance test results of different oversampling methods

过采样方法	A_{cc}	P_{re}	R	F_1
不采样	95.51	94.72	92.51	93.60
ROS	96.68	95.36	93.41	94.37
SMOTE	97.43	95.89	94.39	95.14
B-SMOTE	97.99	97.28	96.23	96.75
ADASYN	98.28	98.01	96.27	97.12
MWMOTE	99.15	99.13	98.81	98.97

4.3 模型性能对比

为了证明本文所提基于 SSA 优化的 KELM 模型的优越性, 将其与粒子群算法 (particle swarm optimization, PSO) 优化的 KELM 进行比较, 同时还考虑了 ELM、KELM、SVM 和 GBDT 等评估模型。

在实验过程中,PSO的粒子种群规模为50,最大迭代次数为200,学习因子 C_1 和 C_2 均设置为2。各模型均运行20次,取20次结果的平均值作为最终的评估结果。所有模型的评估性能结果如表3所示,不同模型训练所需时间、在线评估所需时间对比如表4所示。

表3 不同模型的性能评估结果

Table 3 Performance assessment results of different models

模型	A_{cc}	P_{re}	R	F_1
ELM	97.74	98.13	96.58	97.35
KELM	98.42	98.87	97.45	98.15
SVM	98.16	98.56	97.28	97.91
GBDT	98.84	98.84	98.27	98.55
PSO-KELM	98.96	99.08	98.57	98.82
SSA-KELM	99.15	99.27	98.72	98.97

表4 不同模型的训练和评估时间对比

Table 4 Comparison of training and evaluation durations for different models

模型	训练所需时间/s	在线评估所需时间/ms
ELM	0.356	16.524
KELM	3.286	52.362
SVM	60.785	42.469
GBDT	80.317	60.425
PSO-KELM	8.357	120.367
SSA-KELM	3.942	72.164

表3的测试结果表明,由于GBDT有较强的数据挖掘能力,其评估性能总体要强于结构相对简单的个体模型SVM、KELM和ELM。此外,引入核函数的KELM模型的评估性能优于传统的ELM模型,证明核函数的引入在一定程度上提升了模型的评估能力。基于两种优化算法建立的KELM模型的预测精度显著高于其他模型,其中SSA-KELM获得了最优评估结果,表明相较于其他模型,SSA-KELM更适用于电力系统静态电压稳定性评估领域。表4的测试结果显示,尽管ELM在训练速度上具有明显优势,但由于其输入权重和隐含层偏置采用随机设定,导致模型的最优性能受到一定限制。相比之下,SSA-KELM与KELM的训练时间差异较小,而PSO-KELM的训练耗时约为KELM的两倍。这一现象归因于SSA相较于PSO具有更高的

寻优精度和更快的收敛速度,能够更快地寻找参数解。本文所提评估模型的评估时间仅为0.07 s,虽然略长于结构相对简单的基模型SVM、GBDT、KELM和ELM,但其评估结果优于这些模型。综合来看,本文提出的模型性能最佳,能够满足电力系统实时响应的要求。

4.4 抗噪性能测试

在实际应用中,考虑到PMU在数据采集过程中可能出现测量误差进而影响模型的评估结果。因此,本文对SSA-KELM模型的抗噪性能进行了测试。

为了模拟PMU的测量误差,本文在测试集中加入不同信噪比的高斯白噪声进行实验。根据IEEE C37.118标准,PMU测量的误差应小于1%^[25],而20 dB信噪比的数据中含有1%的噪声。本文设置10、20、30、40 dB 4种噪声对SSA-KELM、PSO-KELM、KELM、ELM、SVM、GBDT 6种模型进行评估,结果如图7、8所示。

图7、8的测试结果表明,SVM、ELM学习能力有限,对噪声的鲁棒性并不强。KELM由于引入了核函数,相比ELM能够获得更加稳定的评估结果。SSA优化的核参数在中等信噪比下更适应带噪数据的特征分布,从而提升对噪声的鲁棒性;而当信噪比进一步增大时,输入数据接近纯净样本,但SSA-KELM因核函数过度适应带噪训练集,可能导致对纯净数据的泛化能力略有下降。SVM基于间隔最大化原理,对支持向量附近的噪声极为敏感,可能导致因噪声点被误选为支持向量而性能骤降;GBDT通过树结构逐层分裂,可能因噪声在部分分裂节点上引入“伪增益”,暂时提升分裂效果,形成准确率“伪峰”。总体来说,基于SSA优化的KELM模型与其他5种模型相比,其 A_{cc} 和 F_1 最高,对噪声的鲁棒性较强,具有更高的应用价值。




图7 不同噪声下的准确率测试结果

Figure 7 Accuracy test results under different noises




图8 不同噪声下的F1值测试结果

Figure 8 F1 value test results under different noises

4.5 泛化能力测试

电力系统的拓扑结构可能会因为检修等原因而发生变化,离线生成的数据集难以涵盖电力系统所有潜在的运行工况^[26]。当系统的运行工况发生变化时,离线训练好的评估模型的性能也会受到影响。因此,为测试本文所提静态电压稳定评估方法应对系统拓扑结构变化的泛化能力,本文通过随机改变系统的网络结构来生成新的场景,如表5所示。

表5 拓扑结构变化情况

Table 5 Variation of topology structure

场景	类型
1	断开线路 2-30
2	断开 9 号发电机
3	断开线路 3-18 和线路 27-28
4	断开 6 号发电机和线路 16-24
5	断开线路 6-11、线路 20-34 和线路 8-9

表5中人为构造的拓扑扰动场景并非基于特定故障概率,而是通过极端、随机的结构变化,检验模型在未见过的拓扑条件下的性能。这种设计可避免模型对特定故障模式的过拟合,更贴近实际系统中的评估需求。对于每种场景,生成500个新的测试样本,使用训练好的SSA-KELM模型进行测试。测试结果如图9所示。




图9 不同场景下的测试结果

Figure 9 Test results under different scenarios

由图9中测试结果可以看出,当电力系统的拓扑结构发生变化时,SSA-KELM模型的评估性能略有下降,但下降幅度不大,仍能保持较高的 A_{cc} 和 F_1 。本文所提方法在面对网络拓扑结构变化时具有较强泛化能力,能够应用于实际电力系统中。

5 结语

针对样本类别不平衡问题,本文提出了一种基于MWMOTE和SSA-KELM的电力系统静态电压稳定评估方法。在新英格兰10级39节点系统上进行性能测试,主要得出以下结论:

1) 使用MWMOTE过采样算法解决样本类别不平衡问题,相比于ROS、SMOTE、B-SMOTE和ADASYN 4种过采样算法,其处理数据不平衡问题的效果最好,对SSA-KELM评估模型的性能提升效果最为显著;

2) 与ELM、KELM和PSO-KELM 3种数据驱动模型相比,SSA-KELM模型在应用于静态电压稳定评估领域时,其 A_{cc} 和 F_1 最高,效果最好;

3) 针对噪声问题和拓扑结构变化问题,本文所提SSA-KELM模型的性能未出现明显下降,表明本文所提模型具有较好的泛化能力。

尽管本文所提方法在静态电压稳定评估中表现出显著优势,但仍存在一些局限性。SSA-KELM虽在精度上优于传统模型,但其决策逻辑的透明性仍弱于基于物理机理的稳定性分析方法,后续将结合特征重要性可视化技术提升可解释性。

参考文献:

- [1] 赵建伟,李禹鹏,杨增辉,等.基于拟蒙特卡罗模拟和核密度估计的概率静态电压稳定计算方法[J].电网技术,2016,40(12):3833-3839.
ZHAO Jianwei, LI Yupeng, YANG Zenghui, et al. Probabilistic static voltage stability calculation based on quasi-Monte Carlo and kernel density estimation[J]. Power System Technology, 2016, 40(12): 3833-3839.
- [2] 邹世豪,曹永吉,刘志文,等.计及多时间尺度电压失稳模式的电网薄弱环节辨识[J].电力系统保护与控制,2024,52(21):35-49.
ZOU Shihao, CAO Yongji, LIU Zhiwen, et al. Identification of grid weak link considering voltage instability patterns at multiple time scales[J]. Power

- System Protection and Control, 2024, 52(21): 35-49.
- [3] 张尧, 张建设, 袁世强. 求取静态电压稳定极限的改进连续潮流法[J]. 电力系统及其自动化学报, 2005, 17(2): 21-25.
ZHANG Yao, ZHANG Jianshe, YUAN Shiqiang. Improved continuation power flow algorithm for obtaining the limit of static voltage stability[J]. Proceedings of the CSU-EPSA, 2005, 17(2): 21-25.
- [4] BEGOVIC M M, PHADKE A G. Voltage stability assessment through measurement of a reduced state vector[J]. IEEE Transactions on Power Systems, 1990, 5(1): 198-203.
- [5] 郭瑞鹏, 韩祯祥, 王勤. 电压崩溃临界点的非线性规划模型及算法[J]. 中国电机工程学报, 1999, 19(4): 14-17.
GUO Ruipeng, HAN Zhenxiang, WANG Qin. Nonlinear programming model & algorithm for point of collapse [J]. Proceedings of the CSEE, 1999, 19(4): 14-17.
- [6] 刘炼, 王强, 陈浩. 基于改进随机森林的电力系统暂态稳定评估[J]. 科学技术与工程, 2022, 22(11): 4367-4374.
LIU Lian, WANG Qiang, CHEN Hao. Transient stability assessment of power system based on improved random forest[J]. Science Technology and Engineering, 2022, 22(11): 4367-4374.
- [7] 李京, 刘道伟, 安军, 等. 基于强化学习理论的静态电压稳定裕度评估[J]. 中国电机工程学报, 2020, 40(16): 5136-5147.
LI Jing, LIU Daowei, AN Jun, et al. Static voltage stability margin assessment based on reinforcement learning theory[J]. Proceedings of the CSEE, 2020, 40(16): 5136-5147.
- [8] LIU S K, SHI R Y, HUANG Y H, et al. A data-driven and data-based framework for online voltage stability assessment using partial mutual information and iterated random forest[J]. Energies, 2021, 14(3): 1-16.
- [9] 陈宝平, 林涛, 黄华, 等. 一种新的静态电压稳定性评估指标[J]. 电力科学与技术学报, 2018, 33(3): 37-43.
CHEN Baoping, LIN Tao, HUANG Hua, et al. A new evaluation index for static voltage stability[J]. Journal of Electric Power Science and Technology, 2018, 33(3): 37-43.
- [10] 胡超凡, 陈睿康, 汤凡, 等. 大规模光储接入下的静态电压特性分析[J/OL]. 发电技术, 1-10[2025-09-24]. <https://link.cnki.net/urlid/33.1405.TK.20250922.1720.002>.
HU Chaofan, CHEN Ruikang, TANG Fan, et al. Analysis of static voltage characteristics under large-scale photovoltaic-energy storage access[J/OL]. Power Generation Technology, 1-10[2025-09-24]. <https://link.cnki.net/urlid/33.1405.TK.20250922.1720.002>.
- [11] 胡常胜, 摆志俊, 张章, 等. 计及静态电压稳定裕度的电制氢容量和布点规划研究[J]. 中国电力, 2025, 58(5): 91-101.
HU Changsheng, BAI Zhijun, ZHANG Zhang, et al. Research on capacity and distribution planning of electric hydrogen production considering static voltage stability margin[J]. Electric Power, 2025, 58(5): 91-101.
- [12] 陈一丰, 黄铭浩, 董树锋. 计及配电侧分布式电源的输配协同高收敛性最优潮流研究[J]. 电力工程技术, 2024, 43(4): 36-44.
CHEN Yifeng, HUANG Minghao, DONG Shufeng. Research on improving the convergence of optimal power flow of transmission-distribution-coupled networks[J]. Electric Power Engineering Technology, 2024, 43(4): 36-44.
- [13] 杨有慧, 陈明媛, 覃芳璐, 等. 基于拉丁超立方重点采样的静态电压稳定概率评估法[J]. 广西电力, 2022, 45(3): 44-52.
YANG Youhui, CHEN Mingyuan, QIN Fanglu, et al. A probabilistic evaluation method of static voltage stability based on Latino hypercube important sampling[J]. Guangxi Electric Power, 2022, 45(3): 44-52.
- [14] 晏光辉, 刘颂凯, 张磊, 等. 基于迁移学习的智能静态电压稳定评估方案[J]. 电测与仪表, 2022, 59(2): 92-99.
YAN Guanghui, LIU Songkai, ZHANG Lei, et al. Intelligent static voltage stability assessment scheme based on transfer learning[J]. Electrical Measurement & Instrumentation, 2022, 59(2): 92-99.
- [15] 徐焕, 夏凡, 陈铨, 等. 基于 GCN-LSTM 的电力系统暂态电压稳定评估[J]. 高压电器, 2025, 61(1): 104-111+144.
XU Huan, XIA Fan, CHEN Shi, et al. Transient voltage stability assessment of power system based on GCN-LSTM[J]. High Voltage Apparatus, 2025, 61(1): 104-111+144.
- [16] 赵万明, 黄彦全, 谌贵辉. 基于支持向量机的电力系统静态电压稳定评估[J]. 电力系统保护与控制, 2008, 36(16): 16-19.
ZHAO Wanming, HUANG Yanquan, CHEN Guihui. Power system steady-state voltage stability assessment based on support vector machine[J]. Power System Protection and Control, 2008, 36(16): 16-19.
- [17] BARUA S, ISLAM M M, YAO X, et al. MWMOTE: majority weighted minority oversampling technique for imbalanced data set learning[J]. IEEE Transactions on Knowledge and Data Engineering, 2014, 26(2): 405-425.
- [18] 杨锡运, 关文渊, 刘玉奇, 等. 基于粒子群优化的核极限学习机模型的风电功率区间预测方法[J]. 中国电机工程学报, 2015, 35(增刊 1): 146-153.
YANG Xiyun, GUAN Wenyuan, LIU Yuqi, et al. Prediction intervals forecasts of wind power based on

- PSO-KELM[J]. Proceedings of the CSEE, 2015, 35(S1): 146-153.
- [19] XUE J K, SHEN B. A novel swarm intelligence optimization approach: sparrow search algorithm[J]. Systems Science & Control Engineering, 2020, 8(1): 22-34.
- [20] 史训涛, 孙健, 肖小兵, 等. 计及柔性负荷资源的分布式智能电网安全域建模[J]. 电力系统保护与控制, 2025, 53(20): 69-82.
- SHI Xuntao, SUN Jian, XIAO Xiaobing, et al. Modeling of distributed smart grid security region considering flexible load resources[J]. Power System Protection and Control, 2025, 53(20): 69-82.
- [21] YU H L, YANG X B, ZHENG S, et al. Active learning from imbalanced data: a solution of online weighted extreme learning machine[J]. IEEE Transactions on Neural Networks and Learning Systems, 2019, 30(4): 1088-1103.
- [22] 汤迎春, 晏光辉, 张雅婷, 等. 基于约束投票极限学习机的在线静态电压稳定评估[J]. 现代电力, 2022, 39(5): 521-528.
- TANG Yingchun, YAN Guanghui, ZHANG Yating, et al. Online static voltage stability assessment based on constrained voting extreme learning machine[J]. Modern Electric Power, 2022, 39(5): 521-528.
- [23] 周挺, 杨军, 周强明, 等. 基于改进 LightGBM 的电力系统暂态稳定评估方法[J]. 电网技术, 2019, 43(6): 1931-1940.
- ZHOU Ting, YANG Jun, ZHOU Qiangming, et al. Power system transient stability assessment method based on modified LightGBM[J]. Power System Technology, 2019, 43(6): 1931-1940.
- [24] DING X J, LIU J, YANG F, et al. Random radial basis function kernel-based support vector machine[J]. Journal of the Franklin Institute, 2021, 358(18): 10121-10140.
- [25] HE M, VITTAL V, ZHANG J S. Online dynamic security assessment with missing pmu measurements: a data mining approach[J]. IEEE Transactions on Power Systems, 2013, 28(2): 1969-1977.
- [26] 徐艳春, 张婧宇, 张涛, 等. 基于两阶段特征选择的电力系统暂态功角与电压一体化稳定性评估方法[J]. 智慧电力, 2025, 53(4): 11-19.
- XU Yanchun, ZHANG Jingyu, ZHANG Tao, et al. Two-stage feature selection-based integrated transient angle and voltage stability assessment method for power systems[J]. Smart Power, 2025, 53(4): 11-19.