基于边界强化混合采样的两阶段电力系统暂态稳定评估

周生存¹,罗 毅¹,易煊承¹,吴亚宁¹,李 丁¹,雷 成² (1. 华中科技大学 电气与电子工程学院 强电磁工程与新技术国家重点实验室,湖北 武汉 430074; 2. 南方电网能源发展研究院有限责任公司,广东 广州 510530)

摘要:受制于样本固有的不平衡性,基于数据挖掘的暂态稳定预测方法不易用于工程实践,为此,提出一种基于边界强化混合采样的两阶段暂态稳定评估模型。在第1阶段,利用预训练的级联卷积神经网络模型确定 边界和非边界样本集,利用条件生成对抗网络合成边界集失稳样本,并对非边界集稳定样本进行欠采样,以 实现边界强化;在第2阶段,利用混合采样后的重构样本集再训练卷积神经网络模型,以更好地挖掘失稳样 本的隐含特征,并采用改进后的焦点损失函数加强模型对边界集样本的学习能力。新英格兰39节点系统与 南方某省级电网的仿真结果表明,所建模型有效降低了对失稳样本的漏判率,提高了整体预测精度,在样本 极不平衡的情况下仍有良好的评估性能。

关键词:边界强化;混合采样;暂态稳定;不平衡分类;卷积神经网络 中图分类号:TM712 **文献标志码:**A

DOI:10.16081/j.epae.202310021

0 引言

在"双碳"目标下,电力系统呈现"双高"的特点, 即高比例新能源接入与高比例电力电子设备的应 用,这使电力系统的暂态稳定性面临着更加严峻的 挑战^[1]。传统的电力系统暂态稳定评估(transient stability assessment, TSA)方法主要包括时域仿真 法^[2]、能量函数法^[3]等,其准确性和快速性无法同时 满足在线应用的要求。随着广域测量系统的发展, 机器学习技术在TSA方面得到了广泛的应用。机器 学习方法通过离线训练获得系统物理特征与暂态稳 定性的一一映射关系,在线应用时通过实时运行数 据快速预测电力系统的暂态稳定性。

机器学习方法的准确性取决于训练样本的数量 和质量。在电力系统中,样本类别不平衡与分类难 易不平衡严重制约了评估模型性能的提升^[4],由于 失稳样本的数量远少于稳定样本,训练过程中易于 区分的稳定样本凭借数量优势提供了绝大部分的损 失值,主导了梯度下降的方向,这导致模型不能充分 学习失稳样本和困难样本的特征^[4]。在实际应用 中,模型倾向于将失稳样本预测为稳定样本,这给电 力系统带来了严重的问题。

针对样本不平衡问题:文献[5-8]分别采用自适 应代价分配原则、考虑误分类代价的极端学习机、改 进的极限梯度提升算法等赋予失稳样本更高的权

收稿日期:2023-01-02;修回日期:2023-05-20

在线出版日期:2023-10-27

基金项目:中国南方电网有限责任公司科技项目(EDRI-GH-KJXM-2021-101)

Project supported by the Science and Technology Program of China Southern Power Grid(EDRI-GH-KJXM-2021-101)

重,优化梯度下降的方向;文献[9]提出一种集成卷 积神经网络(convolutional neural network,CNN)模 型,利用多种CNN从不同角度挖掘失稳样本的隐含 特征,但是分类器在训练过程中容易受噪声数据和 异常数据的干扰;文献[10]将代价敏感的方法与门 控循环单元(gate recurrent unit,GRU)网络相结合, 通过集成3个具有不同评估倾向的GRU网络改善模 型的倾向性;文献[11]利用多类损失函数的比值量 化不平衡样本对模型的影响,制定修正系数,以解决 模型的评估倾向问题,但是模型对高度不平衡数据 的鲁棒性较差。

实际系统中稳定样本与失稳样本的数量极度不 平衡,仅从算法层面解决样本不平衡问题的效果并 不理想。文献[12-13]利用过采样模型合成失稳样 本,以实现数据增强,在一定程度上解决了类别不平 衡问题,但是该方法没有考虑样本分类的难易程度, 过采样产生的样本多属于易分样本,对模型泛化性 能的提升效果有限。文献[14]采用改进的自适应合 成采样方法降低类别不平衡程度,提高了模型的预 测精度和泛化能力。文献[15]采用改进的深度卷积 生成对抗网络(generative adversarial network, GAN) 增强失稳样本,在线应用时自适应更新离线模型, 提高了预测精度,但该方法可持续学习能力较差,更 新过程复杂。文献[16]构建基于GAN和多通道卷 积神经网络(multichannel convolutional neural network,mCNN)的稳定评估模型,在利用前级mCNN筛 选边界样本集后,通过GAN合成边界集样本,并利 用增强后的重构样本训练后级mCNN,但是该方法 忽视了样本类别不平衡问题,且在线应用时需对边 界样本进行二次评估,不满足在线评估的快速性 要求。

144

为了弥补以上方法的不足,同时考虑样本类别 不平衡与分类难易不平衡的差异性,本文提出一种 基于混合采样的两阶段电力系统TSA模型。首先, 利用原始样本预训练CNN模型,根据预分类结果确 定边界稳定、失稳样本与非边界稳定、失稳样本;其 次,利用CGAN合成边界集失稳样本,并对非边界集 稳定样本进行欠采样,以实现边界强化与类别平衡; 然后,利用重构样本对CNN模型进行再训练,并采 用改进后的焦点损失函数加强对边界集样本的学习 能力;最后,通过新英格兰39节点系统与我国南方 某省级电网验证所建模型的有效性。

1 算法原理介绍

1.1 条件生成对抗网络

条件生成对抗网络^[17](conditional generative adversarial network, CGAN)是GAN最重要的衍生模型之一, CGAN可以通过附加条件信息改进GAN的 生成过程, 控制生成样本的类别。

相较于GAN,CGAN为模型提供了附加条件信息y_a,y_a可以为任意值,一般取期望生成样本的标签。生成器生成样本不仅受随机噪声z的影响,还受附加条件信息的影响。同样地,判别器既要判断生成样本的真实性,又要甄别生成样本是否满足给定的条件。当判别器与生成器达到纳什均衡时CGAN模型收敛,CGAN能够比GAN生成更具特征描述性的样本。CGAN函数min max V(D,G)如式(1)所示。

$$\min_{G} \max_{D} V(D, G) = E_{\mathbf{x} \sim P_{data}(\mathbf{x})} \Big[\ln D \Big(\mathbf{x} | \mathbf{y}_{a} \Big) \Big] + E_{\mathbf{z} \sim P_{a}(\mathbf{z})} \Big[\ln \Big(1 - D \Big(G \Big(\mathbf{z} | \mathbf{y}_{a} \Big) \Big) \Big) \Big] (1)$$

式中: $G(\cdot)$ 为生成器的输出值; $D(\cdot)$ 为判别器的输出 值; $E_{x \sim P_{data}(x)} \left[\ln D(x|y_a) \right]$ 、 $E_{z \sim P_{s}(z)} \left[\ln \left(1 - D(G(z|y_a)) \right) \right]$ 分别为函数 $\ln D(x|y_a)$ 在真实数据分布 $P_{data}(x)$ 下、 $\ln \left(1 - D(G(z|y_a)) \right)$ 在先验噪声分布 $P_z(z)$ 下的数学 期望,x 为真实数据,z为随机噪声。

1.2 基于聚类的欠采样方法

在不平衡数据的分类问题中,模型具有倾向于 关注多数类样本、忽视少数类样本的特征。对多数 类样本进行欠采样能够平衡类的分布,有助于提高 模型对少数类样本的预测精度。但是传统的随机欠 采样方法可能导致类数据出现堆叠现象^[18],甚至删 除多数类样本中的重要信息,从而导致数据缺失。 针对该问题,本文提出一种距离加权欠采样方法,该 方法首先将所有样本随机聚类为K个簇,第i个簇为:

$$C_{i} = \left\{ \boldsymbol{x}_{i1}, \boldsymbol{x}_{i2}, \cdots, \boldsymbol{x}_{ij}, \cdots, \boldsymbol{x}_{iN-1}, \boldsymbol{x}_{iN} \right\} \quad i = 1, 2, \cdots, K \quad (2)$$
$$\boldsymbol{\mu}_{i} = \left(\boldsymbol{x}_{i1} + \boldsymbol{x}_{i2} + \cdots + \boldsymbol{x}_{ij} + \cdots + \boldsymbol{x}_{iN-1} + \boldsymbol{x}_{iN} \right) / N \quad (3)$$

式中: C_i 为第i个簇的样本集合; \mathbf{x}_{ij} 为 C_i 中的第j个样本;N为 C_i 中的样本总数; $\boldsymbol{\mu}_i$ 为第i个簇的簇中心。

在确定*C_i*后,在簇内计算样本*x_{ij}*的距离加权指标*D_{ij}*,根据*D_{ij}*计算样本*x_{ij}*被采样的概率。*D_{ij}*的具体计算方法如下。

1)计算簇内每个样本至簇中心的距离,即:

$$d_{ij} = \sqrt{\sum_{m=1}^{N} \left(x_{ijm} - \mu_{im} \right)^2}$$
(4)

式中: d_{ij} 为样本 \mathbf{x}_{ij} 至簇中心 $\boldsymbol{\mu}_i$ 的距离; x_{ijm} , $\boldsymbol{\mu}_{im}$ 分别 为样本 \mathbf{x}_{ii} 与簇中心 $\boldsymbol{\mu}_i$ 的第m维特征。

2)计算簇中心与簇内样本的相似度指标 W_i,即:

$$W_{ij} = \cos\left(\mathbf{x}_{ij}, \boldsymbol{\mu}_{i}\right) = \frac{\sum_{m=1}^{N} x_{ijm} \boldsymbol{\mu}_{im}}{\sqrt{\sum_{m=1}^{N} x_{ijm}^{2}} \sqrt{\sum_{m=1}^{N} \boldsymbol{\mu}_{im}^{2}}}$$
(5)

式中: $\cos(\mathbf{x}_{ij}, \boldsymbol{\mu}_{i})$ 表示 \mathbf{x}_{ij} 与 $\boldsymbol{\mu}_{i}$ 的相似程度。

3)计算簇内样本x;;的距离加权指标,即:

$$D_{ij} = W_{ij}/d_{ij} \tag{6}$$

由式(6)知, D_{ij} 越大说明簇内样本 x_{ij} 至簇中心 样本 μ_i 的距离越近,且与 μ_i 越相似。在欠采样的过 程中,应对 D_{ij} 较大的数据采用较小的选择概率,对 D_{ij} 较小的数据采用较大的选择概率,这样可以有效 避免类数据的重叠,保证样本的多样性。

1.3 改进焦点损失函数

针对样本不平衡问题,改进焦点损失函数通过 引入权重因子和调制因子增加少数类样本与难分类 样本的权重,如式(7)所示。

$$L_{\rm fl} = \begin{cases} -\alpha \left(1 - y'\right)^{\beta} \ln y' & y = 1\\ -(1 - \alpha) \left(y'\right)^{\beta} \ln \left(1 - y'\right) & y = 0 \end{cases}$$
(7)

式中: L_n 为焦点损失函数; $\alpha \in [0,1]$ 为权重因子; β 为 调制因子; $y' \in [0,1]$ 为样本的预测值;y为样本的真 实标签。

式(7)通过对 α 合理赋值解决类别不平衡问题, 即提高少数类样本的权重,降低多数类样本的权重; 调制因子 β 是非负实数,用于降低易分类样本的权 重,提高难分类样本的权重。假设样本的真实标签 为1,若预测值y'接近1,则说明该样本易于区分,模 型不需要过度关注该样本,通过显著减小的 $(1-y')^{\beta}$ 降低权重;若预测值y'接近0,则说明该样本难以区 分,此时 $(1-y')^{\beta}$ 并未受到影响,可以保证模型对该 样本的学习能力。

2 基于CNN的TSA

2.1 CNN 的构造

CNN主要包含卷积层、池化层、全连接层等。卷 积层采用共享卷积核技术,能快速处理高维数据,自 动提取数据内部的隐含特征;池化层可有效降低数 据的维度,提高训练速度;通过全连接层和Sigmoid 函数得到输出值 $\gamma(0 < \gamma < 1)$ 。本文CNN的结构如附 录A图A1所示,具体参数如附录A表A1所示。

2.2 边界强化混合采样模型设计

根据预训练CNN模型的分类结果获得边界、非 边界样本集,并通过CGAN合成边界集失稳样本,同 时对非边界集稳定样本进行欠采样,在改善类别不 平衡的同时,能够提高边界样本集的比例,实现边界 强化。

2.2.1 基于CGAN的过采样模型设计

通过CGAN模型生成边界集失稳样本,实现边 界集中样本的类别平衡。假设边界集中稳定、失稳 样本分别为 B_{1}^{1} 和 B_{1}^{1} ,其数量分别为 n_{1}^{1} 和 n_{1}^{1} ,则边界 集样本的不平衡程度可以表示为:

$$d^{1} = n_{s}^{1} / n_{u}^{1} \tag{8}$$

式中:d¹为边界中稳定与失稳样本的数量比。

基于CGAN的过采样率L¹为:

$$L^1 = kd^1 \tag{9}$$

式中:k为调节因子,k=1时可实现边界集中样本类 别的绝对平衡。

需要生成的边界集失稳样本数量N¹为:

$$N^{1} = L^{1} n_{u}^{1} \tag{10}$$

CGAN模型的结构如附录A图A2所示。生成器 采用卷积层以保证生成样本的可靠性;判别器采用 卷积层和全连接层,能够充分挖掘样本特征,提高模 型的判别精度。

样本生成器同时输入随机噪声z和附加的条件 信息 y_a,将采用 one-hot 编码的样本标签作为条件信 息,分别用[1,0]和[0,1]表示稳定、失稳样本。判别 器通过真实的边界失稳样本进行训练,从而获得判 断样本真实性的泛化能力,利用Sigmoid函数的输出 值表征生成样本的可靠性,当判别器的输出结果为 0.5时,说明生成样本接近真实样本。CGAN的详细 参数如附录B表B1、B2所示。

2.2.2 基于聚类的欠采样模型设计

利用基于聚类的距离加权欠采样模型筛选具有 代表性的非边界集稳定样本,以实现非边界集中样 本的类别平衡。假设非边界集中稳定、失稳样本分 别为 B_{a}^{2} 和 B_{u}^{2} ,其数量分别为 n_{a}^{2} 和 n_{u}^{2} ,则非边界集样 本的不平衡程度可以表示为:

$$d^2 = n_{\rm s}^2 / n_{\rm u}^2 \tag{11}$$

式中:d²为非边界集中稳定与失稳样本的数量比。

模型的欠采样率L²为:

$$L^2 = k/d^2 \tag{12}$$

根据欠采样率和簇密度计算采样数,即: $C''_{i} = C'_{i}/L^{2}$

式中:C"为第i个簇的采样数;C'为第i个簇的样 本数。

在确定 C"后, 根据式(6) 计算每个样本的距离加 权指标D_i,根据概率抽样,直至达到采样数。

2.3 TSA 流程

基于边界强化混合采样的两阶段电力系统TSA 的基本流程如图1所示(图中PMU为相量测量单 元),主要包括离线训练和在线评估两部分。



Fig.1 Flowchart of TSA

2.3.1 输入特征的构建

参考文献[9],本文选择故障切除后t个周期内 发电机有功功率、无功功率、机端电压、角速度和功 角的采样值作为模型的输入特征。若系统发电机的 数量为 $N_{\rm G}$,则一个样本共含有 $5N_{\rm G}$ ×2t个特征。根据 图2的堆叠方式构造三维特征空间。图中, $\delta_{1\tau}$ 、 P_{1,T_1} , Q_{1,T_1} , U_{1,T_1} , ω_{1,T_1} 分别为发电机1的功角、有功功 率、无功功率、机端电压和频率,其他类似。

2.3.2 离线训练

1)获取训练数据并构建输入特征结构图,根据 仿真得到的暂态稳定结果设置标签值。

2)数据预处理。通过式(14)对原始样本进行均 方差归一化处理,消除不同特征量纲之间的差异,确 保所有数据的均值为1以及方差为0,以提高收敛 速度。



图2 特征图构建

Fig.2 Construction of feature map

$$\hat{x} = (x - \mu_x) / \sigma_x \tag{14}$$

式中: \hat{x} 为经过均方差归一化处理后的值; μ_x 、 σ_x 分别为原始数据x的均值和标准差。

3)样本集划分。利用原始样本对 CNN 模型进 行预训练,通过预训练模型依次评估每个样本,根据 判别值γ划分边界集和非边界集。

根据判别值γ判断样本是否稳定:当γ>0.5时, 认为样本稳定;当γ<0.5时,认为样本失稳。对于稳 定样本,γ越大,说明样本越易区分,当γ接近0时, 认为该样本属于极难分类的异常样本,可以舍弃;同 理,对于失稳样本,γ越小,说明样本越易区分,当γ 接近1时,认为该样本属于异常样本。具体划分原则 如表1所示,样本划分的上、下阈值分别为0.9、0.1。

表1 边界集划分

Table 1 Partition of boundary set

长木		γ范围	
件华	非边界集	边界集	异常样本
稳定样本	$0.9 < \gamma < 1$	$0.1 < \gamma < 0.9$	$\gamma < 0.1$
失稳样本	$0 < \gamma < 0.1$	$0.1 < \gamma < 0.9$	$\gamma > 0.9$

4) 混合采样。对边界集失稳样本利用 CGAN 进行过采样, 对非边界集稳定样本进行欠采样, 最终得到实现类别平衡的重构样本集。

5)再训练。利用混合采样后的重构样本对CNN 模型进行再训练,在训练过程中,冻结部分CNN的 卷积层,仅训练其余网络层,以解决"灾难性遗忘" 问题^[19]。

2.3.3 在线评估

在线评估是将各发电机处的 PMU 量测数据进 行预处理后输入 CNN 模型中,给出暂态稳定判别结 果。工作人员根据输出结果决定是否采取稳定控制 措施,以防止重大停电事故发生。

2.4 评估指标

根据故障后发电机转子功角的暂态稳定指数 *T*_{s1}^[20] 判断样本的稳定性,*T*_{s1}计算公式为:

$$T_{\rm SI} = \frac{360 - \left|\Delta\delta_{\rm max}\right|}{360 + \left|\Delta\delta_{\rm max}\right|} \tag{15}$$

式中: $\Delta\delta_{max}$ 为任意2台发电机的最大功角差。

当 $T_{st}<0$ 时,说明存在2台发电机的功角差大于 360°,认为系统功角失稳,此时样本标签为0;当 $T_{st}>$ 0.33时,说明任意2台发电机的功角差均小于180°, 系统功角稳定,样本标签为1。根据我国最新颁布 的GB/T 40581—2021《电力系统安全稳定计算规 范》中的判据"多机复杂系统在摇摆过程中,任两机 组间的相对角度超过180°,但仍能恢复到同步衰减 而逐渐稳定时,认为系统是稳定的",当 $T_{st} \in (0,$ 0.33)时,需要根据时序采样数据进一步判定系统稳 定性,若系统能恢复到同步衰减,则认为系统稳定, 否则认为系统失稳。基于混淆矩阵选择准确率 A_{cex} G_{mean} 指标以及 F_1 分数指标作为模型的评估标准, 3个指标的具体表达式分别如附录B式(B1)—(B3) 所示。

3 算例分析

为验证所提方法的有效性,本文选择新英格兰39节点系统与我国南方某省级电网进行仿真分析,仿真工具为PSD-BPA。在PyTorch环境中使用Python语言搭建评估模型,PC配置为Intel Core i5-11400F CPU / 16.0 GB RAM。

3.1 新英格兰39节点系统

3.1.1 样本生成

新英格兰39节点系统共有10台发电机、12台 变压器和46条线路,基准电压为345 kV,基准功率 为100 MW。仿真时,设置负荷为恒阻抗模式,负荷 水平为标准负荷的75%~125%,步长为5%,共11种 负荷水平,根据负荷水平相应地调节发电机出力,在 潮流收敛时进行故障情况下的暂态稳定计算。本文 选择对电网影响最严重的三相短路故障,暂态失稳 情况仅发生在系统受到严重扰动后。分别在母线 首、末端(分别距离母线首端5%、95%的线路长度 处)设置三相短路故障,故障持续时间为0.1~0.3 s, 设置步长为1个周期(约0.016 s),仿真时长为10 s, 采样间隔为0.5个周期(约0.0083 s)。根据式(15) 的暂态稳定指数,失稳样本标签取为0,稳定样本标 签取为1。仿真获得12189个有效样本,包括7079个 稳定样本和5110个失稳样本。

3.1.2 调节因子对模型性能的影响

在2.2节边界强化混合采样模型的设计中,调节 因子 k 决定了重构样本中边界集强化的程度,当 k=1 时,可以实现重构样本中类别的绝对平衡。由式 (12)可知,采样模型中调节因子的取值范围为 [0, d²],通过设置不同的 k 值可以研究再训练过程中 重构样本对模型性能提升的影响。定义综合指标 M_a ,将其作为对k的最终选择依据, M_a 的计算公式如式(16)所示。

$$M_{\rm a} = (A_{\rm cc} + F_{\rm 1} + G_{\rm mean})/3 \tag{16}$$

k对模型性能的影响如附录 C 表 C1 所示。根据 M_a 可知,当k=1.2时,重构样本对模型性能的提升效 果最佳,因此,在后文中,采样模型的调节因子均取 为1.2。此外, A_{ee} 、 F_1 、 G_{mean} 指标与调节因子间并非单 调关系,分别在k取值1.1、1.3、1.2时最佳。

3.1.3 不同模型性能分析

仿真验证本文提出的两阶段 CNN 评估模型,并 与稳定评估中的几种经典模型进行对比,即人工神 经网络(artificial neural network, ANN)、支持向量机 (support vector machine, SVM)、*k* 近邻算法(*k*-nearest neighbor, kNN)、决策树(decision tree, DT)、随 机森林(random forest, RF)和长短期记忆(long shortterm memory, LSTM)网络。

本文采用6层的CNN模型,卷积核大小为3×3, 采用AdamW优化器实现权重衰减,并且自适应调节 学习率,采用小批量梯度下降法来提高训练效率,设 置batch size为64,迭代次数为200。上述经典算法 中:SVM采用径向基核函数算法;kNN基于欧氏距离 确定被评估样本的k近邻;DT采用C4.5算法,利用 基尼指数进行属性划分;RF中的最大树深为6; LSTM网络的结构设计为单层网络,最后一个时间步 接全连接层;各算法中的批量等超参数均与CNN一 致。在原始样本和重构样本中,均取80%的样本构 成训练集,其余20%的样本构成测试集,且训练集 和测试集中的稳定、失稳样本的比例与样本的不平 衡度保持一致,利用五折交叉验证法进行模型评估。 各模型性能如表2所示。

表 2 不同 TSA 模型性能比较 Table 2 Performance comparison among

different TSA models

模型	输入	$A_{\rm cc}$	F_{1}	G_{mean}
CNN	原始样本+重构样本	0.9903	0.9829	0.9895
ANN	原始样本	0.9831	0.9772	0.9841
SVM	原始样本	0.9732	0.9613	0.9701
kNN	原始样本	0.9588	0.9475	0.9544
DT	原始样本	0.9178	0.9243	0.9167
RF	原始样本	0.9389	0.9407	0.9476
LSTM	原始样本	0.9847	0.9681	0.9718

由表2可知,经原始样本与重构样本两阶段训 练的CNN模型在3种评估指标上的表现均最佳。在 第1阶段的训练中,CNN模型充分学习了全体样本 的特征,但是由于数据不平衡,模型的输出倾向于数 量更多的非边界集稳定样本,此时模型的漏判率和 误判率处于一个相对较高的水平。为了解决该问 题,在第2阶段,模型通过混合采样后的重构样本针 对性地学习边界集样本和失稳样本的特征,提高了 对失稳样本和难分类样本的判别能力。此外,相较 于浅层的机器学习模型,以CNN、ANN为代表的深 度学习模型有更好的表现,这是由于深度学习模型 能够更好地表征复杂的映射函数,捕捉数据的内部 特征。

3.1.4 可视化分析

Fig.3

为了对数据分布以及模型的评估结果有直观 的认识,采用t分布式随机邻居嵌入(t-distributed stochastic neighbor embedding,t-SNE)降维算法将数 据分布与全连接层的输出映射到二维空间中。t-SNE 根据数据的相似性进行降维,在低维空间呈现的位 置与相似度有关。图3和图4分别为可视化下样本 数据和全连接层生成数据的分布情况。



图 3 可视化下的样本数据分布

Sample data distribution under visualization





由图3(a)可知,原始样本中的稳定、失稳样本相 互交织,不存在明确的边界,且稳定样本多于失稳样 本。图3(b)是混合采样后的数据集分布,重构数据 集保留了原始样本的失稳样本和边界集稳定样本, 并利用过采样对边界集失稳样本进行数据增强,如 图中绿点所示。混合采样后的重构数据集数据少于 原始数据集数据,且数据分布更加均衡。

图4(a)为预训练模型稳定判别结果的可视化分 布,输出结果存在较明确的边界,可见预训练模型经 抽象学习后能够有效地提取数据特征。然而,由于 原始数据的高度不平衡,模型倾向于将失稳样本预测为稳定样本,部分边界样本被错误分类。图4(b) 是再训练后 CNN 模型的可视化输出,结果有明确的 暂态稳定边界,此时模型的分类性能明显优于预训 练 CNN。经分析知,再训练后的 CNN 模型通过学习 重构样本的隐含特征纠正了预训练 CNN 模型的倾 向性,在保证准确率不降低的前提下,最大限度地减 少了对失稳样本的漏判。

3.1.5 模型对不平衡数据的鲁棒性分析

为验证模型在不平衡数据上的分类性能,在多 种不平衡比的样本集上研究模型的鲁棒性,定义数 据集的不平衡比λ为:

$$\lambda = (n_{\rm TS} + n_{\rm FS})/n \tag{17}$$

式中:n_{TS}、n_{FS}分别为稳定样本、失稳样本中被预测正确的数目;n为样本的总数。

由 λ 的定义可知,当 λ =0.5时,样本平衡, λ 越大 (越小)说明稳定(失稳)样本越多,样本越不平衡。 固定不同子集中的样本总数为4000,当λ分别取 0.5、0.6、0.7、0.8、0.9时,各模型的A_{cc}、F₁、G_{mem}变化如 附录C图C1所示。由图可知:随着λ的增大,ANN、 RF、CNN模型的整体预测准确率 A_{cc} 没有较大变化, 这是由于样本总数是固定的,模型在多数类和少数 类样本上的分类精度不同,可见整体准确率不能作 为不平衡数据下模型的有效评估标准:根据F,指 标,随着失稳样本的不断减少,训练模型倾向于将失 稳样本预测为稳定样本,各模型的F,指标均有一定 程度的下降,其中CNN的抵抗性最好;根据 G_{men} 指 标,当 λ =0.5时,各模型的 G_{mean} 值最优,随着 λ 的增 大,上述模型在Gmean指标上的表现均有不同程度的 下降;综合 A_{cc} 、 F_1 、 G_{mean} 指标可知,经两阶段训练的 CNN模型对高度不平衡的数据集仍然具有较好的鲁 棒性。

3.2 我国南方某省级电网

为进一步验证所提方法的适用性,在南方某省级电网上进行进一步的研究,在丰大运行方式下,分别调整新能源渗透率为1.9%、11.53%、16.87%,选择40条交流互联线路,以线路长度的10%为步长,在距离首端5%~95%的线路长度范围内设置三相短路故障;利用PSD-BPA软件进行仿真,设置仿真时间为10s,故障持续时间为0.2~0.4 s,步长为0.02 s,采样时间为0.005 s。仿真共生成10764个有效样本,其中有9545个稳定样本和1219个失稳样本。相较于新英格兰39节点系统,该南方省级电网的架构更加稳定,生成样本的不平衡程度更高,能更有效地对本文所提方法进行验证。

将本文所提模型与ANN、SVM、DT、RF、LSTM网络模型进行对比。模型训练时的超参数均与3.1节

中保持一致。最终得到各模型的评估性能如附录C 表 C2 所示,所提模型的A_{cc}、F₁、G_{mean}指标分别为 0.9907、0.9815、0.9872,均为最优值。固定样本子 集的样本总数为4000,在不同的不平衡比下采用综 合评估指标M作为评估依据,各模型的评估效果如 表3所示。

表3 不同不平衡比下的评估效果

Table 3 Assessment results under

different imbalance ratios

描刊	М				
医至	0.70	0.75	0.80	0.85	0.90
CNN	0.9810	0.9796	0.9781	0.9753	0.9714
ANN	0.9713	0.9685	0.9669	0.9614	0.9552
SVM	0.9642	0.9586	0.9517	0.9478	0.9423
DT	0.9174	0.9135	0.9102	0.9135	0.8995
\mathbf{RF}	0.9367	0.9284	0.9226	0.9157	0.9113
LSTM	0.9686	0.9623	0.9516	0.9524	0.9453

注:栏目中数据为不平衡比取值。

由表3可知:随着不平衡比的增大,模型的评估 性能均呈下降趋势,其中两阶段CNN模型容忍数据 不平衡的能力最强;随着不平衡比的增大,ANN、 SVM等模型与两阶段CNN模型评估性能的差距不 断扩大。

在对实际电网样本进行稳定评估时,本文采用的PC评估样本的平均速度为0.83 ms,满足在线应用的要求,随着硬件装置的升级,响应速度还会加快,可见,本文所提方法在实际电网中同样适用。

4 结论

针对电力系统 TSA 中的样本不平衡问题,本文 提出一种基于边界强化混合采样的两阶段 TSA 模型,利用混合采样后的重构数据集对模型进行再训 练。在新英格兰 39 节点系统和我国南方某省级电 网上进行仿真验证,得出以下结论。

1)混合采样后的重构数据集实现了样本内部的 类别平衡与边界强化,相较于失稳样本过采样数据 集,该数据集能同时纠正模型对稳定样本和非边界 样本的倾向性,保证了总体的准确率和召回率。

2)随着样本不平衡程度的加深,CNN、SVM、 RF、LSTM 网络等模型的A_{cc}变化较小,但是表征不平 衡分类算法的G_{mean}和F₁指标均有不同程度的下降, 而经两阶段训练的CNN模型效果最佳,在样本极不 平衡的情况下仍有良好的评估性能。

3)所提两阶段 CNN 模型具有较高的可靠性,在 样本不平衡的条件下,采用混合采样技术能更好地 挖掘边界样本和失稳样本的隐含特征,解决传统方 法的"灾难性遗忘"问题,综合提高数据驱动模型对 电力系统的稳定评估能力。 本文基于混合采样技术确定重构数据集,不同 的采样模型会严重影响生成样本的质量,因此,后续 笔者将重点研究采样模型的改进方法。此外,由于 数据方法忽略了系统的物理特征,其可解释性偏弱, 需要进一步研究数据-物理融合驱动模型在TSA中 的应用。

附录见本刊网络版(http://www.epae.cn)。

参考文献:

[1] 鞠平,周孝信,陈维江,等."智能电网+"研究综述[J]. 电力自动化设备,2018,38(5):2-11.
 JU Ping, ZHOU Xiaoxin, CHEN Weijiang, et al. "Smart Grid

Plus" research overview[J]. Electric Power Automation Equipment, 2018, 38(5): 2-11.

- [2] GURRALA G, DINESHA D L, DIMITROVSKI A, et al. Large multi-machine power system simulations using multi-stage adomian decomposition [J]. IEEE Transactions on Power Systems, 2017, 32(5):3594-3606.
- [3] VU T L, TURITSYN K. Lyapunov functions family approach to transient stability assessment [J]. IEEE Transactions on Power Systems, 2016, 31(2):1269-1277.
- [4] 林楠,王怀远,陈启凡. 基于后验分布信息的SSAE暂态稳定评 估模型倾向性修正方法[J]. 电力自动化设备,2022,42(3): 135-141.
 LIN Nan, WANG Huaiyuan, CHEN Qifan. Tendency correction

tion method of SSAE transient stability assessment model based on posterior distribution information [J]. Electric Power Automation Equipment, 2022, 42(3):135-141.

- [5] WANG H Y, WANG Q Y. Adaptive cost-sensitive assignment method for power system transient stability assessment [J]. International Journal of Electrical Power & Energy Systems, 2022,135:107574.
- [6] 陈振,肖先勇,李长松,等. 基于代价敏感极端学习机的电力 系统暂态稳定评估方法[J]. 电力自动化设备,2016,36(2): 118-123. CHEN Zhen XIAO Xiannang LI Changeong et al. Pause au

CHEN Zhen, XIAO Xianyong, LI Changsong, et al. Power system transient stability assessment based on cost-sensitive extreme learning machine[J]. Electric Power Automation Equipment, 2016, 36(2):118-123.

- [7]张晨宇,王慧芳,叶晓君.基于XGBoost算法的电力系统暂态 稳定评估[J].电力自动化设备,2019,39(3):77-83,89.
 ZHANG Chenyu, WANG Huifang, YE Xiaojun. Transient stability assessment of power system based on XGBoost algorithm[J]. Electric Power Automation Equipment, 2019, 39(3): 77-83,89.
- [8] 邬春明,任继红.基于人工智能的暂态稳定裕度精细化预测
 [J].电力自动化设备,2021,41(12):108-114.
 WU Chunming, REN Jihong. Refined prediction of transient stability margin based on artificial intelligence [J]. Electric Power Automation Equipment,2021,41(12):108-114.
- [9] 李嘉敏,杨红英,闫莉萍,等. 样本不平衡情况下的电力系统 暂态稳定集成评估方法[J]. 电力系统自动化,2021,45(10): 34-41.

LI Jiamin, YANG Hongying, YAN Liping, et al. Integrated assessment method for transient stability of power system under sample imbalance[J]. Automation of Electric Power Systems, 2021,45(10):34-41.

[10] CHEN Q F, WANG H Y. Time-adaptive transient stability assessment based on gated recurrent unit[J]. International

Journal of Electrical Power & Energy Systems, 2021, 133: 107156.

- [11] CHEN Q F,WANG H Y,LIN N. Imbalance correction method based on ratio of loss function values for transient stability assessment[J / OL]. CSEE Journal of Power and Energy Systems. [2022-12-13]. https://ieeexplore.ieee.org/document/ 9770511. DOI:10.17775 / CSEEJPES.2021.00290.
- [12] TAN B D, YANG J, TANG Y F, et al. A deep imbalanced learning framework for transient stability assessment of power system[J]. IEEE Access, 2019, 7:81759-81769.
- [13] 谭本东,杨军,赖秋频,等.基于改进CGAN的电力系统暂态 稳定评估样本增强方法[J].电力系统自动化,2019,43(1): 149-157.

TAN Bendong, YANG Jun, LAI Qiupin, et al. Data augment method for power system transient stability assessment based on improved conditional generative adversarial network [J]. Automation of Electric Power Systems, 2019, 43(1):149-157.

- [14] LIN Y F, WANG X Y. A data-driven scheme based on sparse projection oblique randomer forests for real-time dynamic security assessment[J]. IEEE Access, 2022, 10:79469-79479.
- [15] 李宝琴,吴俊勇,强子玥,等.基于改进DCGAN的电力系统暂态稳定增强型自适应评估[J].电力系统自动化,2022,46(2): 73-82.

LI Baoqin, WU Junyong, QIANG Ziyue, et al. Enhanced adaptive assessment on transient stability of power system based on improved deep convolutional generative adversarial network [J]. Automation of Electric Power Systems, 2022, 46 (2) : 73-82.

- [16] 时纯,刘君,梁卓航,等. 基于 GAN 和多通道 CNN 的电力系统 暂态稳定评估[J]. 电网技术,2022,46(8):3191-3202.
 SHI Chun,LIU Jun,LIANG Zhuohang, et al. Transient stability assessment of power system based on GAN and multi-channel CNN[J]. Power System Technology, 2022, 46(8):3191-3202.
- [17] MIRZA M, OSINDERO S. Conditional generative adversarial nets[EB / OL]. [2022-12-13]. https://arxiv.org / abs / 1411.1784. pdf.
- [18] TAHIR M A, KITTLER J, MIKOLAJCZYK K, et al. A multiple expert approach to the class imbalance problem using inverse random under sampling [M] // Multiple Classifier Systems. Berlin, Germany: Springer, 2009:82-91.
- [19] 李保罗,孙华东,张恒旭,等. 基于两阶段迁移学习的电力系统 暂态稳定评估框架[J]. 电力系统自动化,2022,46(17):176-185.
 LI Baoluo, SUN Huadong, ZHANG Hengxu, et al. Transient stability assessment framework of power system based on twostage transfer learning[J]. Automation of Electric Power Systems,2022,46(17):176-185.
- [20] 李鹏,董鑫剑,孟庆伟,等. 基于Fisher Score特征选择的电力 系统暂态稳定评估方法[J]. 电力自动化设备,2023,43(7): 117-123.

LI Peng, DONG Xinjian, MENG Qingwei, et al. Transient stability assessment method for power system based on Fisher Score feature selection [J]. Electric Power Automation Equipment, 2023, 43(7): 117-123.

作者简介:

周生存(1999—), 男, 硕士研究生, 主要研究方向为人工 智能在电力系统中的应用(E-mail:m202172122@hust.edu.cn);

罗 毅(1966—),男,副教授,博士,通信作者,主要研究 方向为电力系统运行与控制等(E-mail:luoyee@hust.edu.cn)。

Two-stage transient stability assessment of power system based on boundary enhanced hybrid sampling

ZHOU Shengcun¹, LUO Yi¹, YI Xuancheng¹, WU Yaning¹, LI Ding¹, LEI Cheng²

(1. State Key Laboratory of Advanced Electromagnetic Engineering and Technology, School of Electrical and Electronic

Engineering, Huazhong University of Science and Technology, Wuhan 430074, China;

2. Development Research Institute of China Southern Power Grid, Guangzhou 510530, China)

Abstract: Due to the inherent imbalance of samples, the transient stability prediction method based on data mining is tough to be used in engineering practice, for which, a two-stage transient stability evaluation model based on boundary enhanced hybrid sampling is proposed. In the first stage, the pre-trained cascaded convolutional neural network model is used to determine the boundary and non-boundary sample sets, the conditional generative adversarial network is used to synthesize the unstable samples of boundary set, and the stable samples of non-boundary set are under sampled to achieve boundary reinforcement. In the second stage, the convolutional neural network model is retrained with the reconstructed sample set after hybrid sampling to better mine the hidden features of unstable samples, and the improved focal loss function is used for enhancing the learning ability of the model to the samples of boundary set. The simulative results of New England 39-bus system and a provincial power grid in Southern China show that the proposed model can effectively reduce the omission rate of unstable samples, improve the overall prediction accuracy, and still have good evaluation performance in the case of extremely unbalanced samples.

Key words: boundary reinforcement; hybrid sampling; transient stability; imbalanced classification; convolutional neural network

(上接第134页 continued from page 134)

Joint optimization of electric bus reserve rate and charging piles considering real-time traffic characteristics

CAO Fang, ZHENG Yixin, WANG Siqi, WANG Chunyi, QI Yueying

(School of Electrical and Electronic Engineering, North China Electric Power University, Beijing 102206, China)

Abstract: In order to improve the total investment and operation economy of electric buses and charging stations, the purchase cost of buses and charging piles and the charging cost should be considered comprehensively. The driving time and energy consumption of electric buses are calculated with road characteristics, real-time traffic characteristics and environment temperature as the main influencing factors. On the premise of meeting the basic needs of bus operation and ensuring the temperature inside the bus, the joint optimization model of electric bus reserve rate and charging piles is established with the goal of minimizing the sum of the daily purchase cost of buses, the daily construction cost of charging piles and the daily charging cost. The improved discrete adaptive particle swarm optimization algorithm is used to obtain the optimal purchase scheme of buses and charging piles, as well as the average daily investment and operation cost of each season and all the year. The validity of the established optimization model is verified by taking the electric buses on a bus route under various operation conditions in a year as an example.

Key words: electric buses; charging piles; charging station; bus reserve rate; real-time traffic characteristics; joint optimization; environment temperature





图 A1 级联多通道 CNN 结构 Fig.A1 Structure of multi-channel CNN

> 表 A1 级联多通道 CNN 结构 1 Structure of multi-channel CNN

Table A1	Structure of multi-char	nnel CNN
层名称	类型	激活函数
Layer1	Convolution	Relu
Layer2	Max-pooling	—
Layer3	Convolution	Relu
Layer4	Max-pooling	—
Layer5	Convolution	Relu
Layer6	Max-pooling	—
Layer7	Fully connected	—
Layer8	Batch normalization	—
Layer9	Fully connected	—



图 A2 CGAN 模型结构 Fig.A2 Model structure of CGAN

	Table B1	Structure and parameters of generator			erator
层数	名称	卷积核尺寸	卷积核数量	步长	激活函数
Layer1	2D 卷积	3×3	32	2	Leaky ReLU
Layer2	2D 卷积	3×3	64	2	Leaky ReLU
Layer3	2D 卷积	3×3	32	2	Leaky ReLU
Layer4	2D 卷积	3×3	10	2	ReLU

表 B1 生成器结构及参数 Table B1 Structure and parameters of genera

表 B2 判别器结构及参数

Table B2 Structure and parameters of discriminator				ninator		
	层数	名称	卷积核尺寸	卷积核数量	步长	激活函数
	Layer1	2D 卷积	3×3	32	2	Leaky ReLU
	Layer2	2D 卷积	3×3	64	2	Leaky ReLU
	Layer3	2D 卷积	3×3	32	2	Leaky ReLU
	Layer4	2D 卷积	3×3	10	2	Leaky ReLU
	Layer4	全连接层	-	-	-	Sigmoid

表 B3 混淆矩阵

Table B3Confusion matrix

证件	重	真实
ИТПД	稳定	失稳
稳定	n _{TS}	$n_{_{ m TU}}$
失稳	$n_{\rm FU}$	$n_{\rm FS}$

$$A_{\rm cc} = \frac{n_{\rm TU} + n_{\rm TS}}{n} \times 100\% \tag{B1}$$

$$G_{\text{mean}} = \sqrt{\frac{n_{\text{TU}}}{n_{\text{TU}} + n_{\text{FS}}} \cdot \frac{n_{\text{TS}}}{n_{\text{TS}} + n_{\text{FU}}}}$$
(B2)

$$F_{1} = \frac{2 \times \frac{n_{\rm TU}}{n_{\rm TU} + n_{\rm FS}} \cdot \frac{n_{\rm TU}}{n_{\rm TU} + n_{\rm FU}}}{\frac{n_{\rm TU}}{n_{\rm TU} + n_{\rm FS}} + \frac{n_{\rm TU}}{n_{\rm TU} + n_{\rm FU}}}$$
(B3)

式中: n_{TS} 、 n_{TU} 分别为稳定样本、失稳样本中被预测正确的数目; n为样本的总数; n_{FS} 、 n_{FU} 分别为稳定样本、失稳样本中被预测错误的数目; G_{mean} 值为特异度和召回率的几何平均值,是表征不平衡分类算法的重要指标; F_1 为查准率和召回率的调和平均值。

附录 C

10			dei periorina	linee			
Ŀ		评估指标					
к <u></u>	$A_{\rm cc}$	F_1	$G_{\rm mean}$	M_{a}			
0.4	0.982 4	0.972 8	0.975 4	0.976 8			
0.5	0.984 6	0.972 4	0.975 9	0.977 6			
0.6	0.984 8	0.974 6	0.976 4	0.978 6			
0.7	0.985 9	0.975 1	0.978 2	0.979 7			
0.8	0.985 7	0.976 9	0.982 3	0.981 6			
0.9	0.988 4	0.978 8	0.984 4	0.983 9			
1.0	0.988 7	0.979 2	0.987 9	0.985 2			
1.1	0.992 1	0.980 7	0.988 2	0.987 0			
1.2	0.990 3	0.982 9	0.989 5	0.987 6			
1.3	0.991 1	0.983 5	0.987 7	0.987 4			
1.4	0.990 9	0.982 3	0.988 3	0.987 1			
1.5	0.991 5	0.981 9	0.987 6	0.987			
1.6	0.991 3	0.981 8	0.988 7	0.987 2			
1.7	0.990 1	0.982 3	0.987 7	0.986 3			

表 C1 k 对模型性能的影响

Table C1Effect of k on model performance



Fig.C1 Model evaluation indicators under imbalanced conditions

表 C2 中国南方某省级电网中各模型性能比较

Table C2 Performance comparison of various models in a

	provincial power grid in Southern China					
推刑	た)					
侠笙	抽八	$A_{\rm cc}$	F_1	G_{mean}		
CNN	原始+重构	0.990 7	0.981 5	0.987 2		
ANN	原始样本	0.985 1	0.972 3	0.982 4		
SVM	原始样本	0.969 4	0.9503	0.972 1		
KNN	原始样本	0.951 3	0.938 8	0.954 1		
СТ	原始样本	0.921 7	0.908 3	0.910 5		
RF	原始样本	0.931 9	0.922 8	0.951 7		
LSTM	原始样本	0.982 1	0.967 3	0.959 7		

provincial power grid in Southern China