

基于梯度范数的暂态稳定评估模型的不平衡修正方法

胡力涛¹,王怀远¹,党 然²,童浩轩³,张 旻¹

(1. 福州大学 电气工程与自动化学院 福建省新能源发电与电能变换重点实验室,福建 福州 350116;

2. 陕西飞机工业有限责任公司,陕西 汉中 723000;

3. 国网福建省电力有限公司泰宁县供电公司,福建 三明 354400)

摘要:为了解决电力系统中样本数量和质量不平衡造成的暂态稳定评估偏差问题,从评估模型的训练过程出发,通过预训练模型获得样本对模型参数修正的梯度范数,引入梯度范数均值比量化样本的不平衡程度,相较于先验信息,梯度范数均值比综合考虑了样本数量与样本质量的不平衡,并提出基于代价敏感法的不平衡修正方法,利用该方法改善模型的评估倾向性,以实现较好的修正效果。IEEE 39节点系统和华东电网系统的仿真结果验证了所提方法的有效性。

关键词:深度学习;暂态稳定评估;代价敏感;梯度范数;堆叠稀疏自编码器;不平衡样本

中图分类号:TM712

文献标志码:A

DOI:10.16081/j.epae.202308022

0 引言

随着可再生能源发电和交直流输电线路在电力系统中的广泛应用^[1],系统的动态特性变得越来越复杂。另外,随着电力市场的发展,出于经济性的考虑,现代电力系统往往运行在安全稳定约束的边缘^[2],这对电力系统的安全性和稳定性提出了更高的要求。因此,快速、准确的暂态稳定评估方法至关重要。

近年来,随着人工智能技术的快速发展,机器学习在暂态稳定评估中的应用逐渐受到关注。与传统的暂态稳定评估方法相比,通过机器学习可以在更短的时间内预测电力系统的稳定性,并获得较高的预测精度。机器学习方法包括浅层学习方法和深度学习。目前在暂态稳定评估中应用的浅层学习方法包括 k 最近邻^[3]、决策树^[4]和支持向量机^[5]。深度学习具有浅层学习所不具备的数据挖掘能力,可以挖掘出样本集的深层特征,常用的深度学习方法包括深度置信网络^[6]、卷积神经网络(convolutional neural network,CNN)^[7-8]、长短时记忆网络(long short-term memory network,LSTM)^[9]、Transformer^[10]和堆叠稀疏自编码器(stacked sparse auto-encoder,SSAE)^[11]。文献[9]基于LSTM自身输出结果的时序特性,提出多阶段电力系统暂态稳定评估方案,能够更快地给出可信的暂态稳定评估结果。文献[10]提出基于Transformer的暂态稳定评估模型,该模型展现出良好的可解释性,揭示了不同特征对决策的贡献度,提

高了算法决策的可信度。文献[11]将惯量中心频率偏移量的概念引入基于SSAE的模型中,提高了暂态稳定评估模型的泛化能力和分类准确率。

由于电力系统的鲁棒性较强,系统在受到干扰后大多能恢复到稳定状态,因此,系统不稳定现象并不常见,不稳定样本较少。若训练样本集中稳定样本数量过多,深度学习模型在训练过程中会更加关注稳定样本,这容易导致不稳定样本被判别为稳定样本,进而产生评估偏差问题。对于暂态稳定评估问题,若不稳定样本被误判,则会发生电力系统失稳、解列。因此,处理数据集不平衡带来的评估倾向性是人工智能技术应用和推广过程中亟需解决的问题。

目前,针对数据集不平衡的处理方法主要包括数据处理方法和算法处理方法。数据处理方法包括欠采样^[12]和过采样^[13-14],但欠采样会丢失数据集的样本信息,过采样会增加过拟合的风险,模型性能提升有限。算法处理方法主要是代价敏感法^[15-21],该方法的性能取决于所赋值的代价系数。文献[15-16]通过试错的方法确定合适的代价系数矩阵,这需要反复训练模型,会耗费大量的训练时间。文献[17]根据样本的数量比构建代价系数矩阵,但忽略了样本重要性对数据不平衡的影响。文献[18]根据专家经验构造代价敏感矩阵,但根据经验确定代价系数可能不是最合适的。因此,针对数据集不平衡问题,不仅要关注样本数量不平衡对模型的影响,还要考虑样本重要性对数据集不平衡的影响。文献[19]引入后验信息量化模型的评估偏差程度,综合考虑样本数量和空间分布信息对模型的影响。文献[20]提出的图注意力神经网络结合代价敏感法将不稳定样本数量与稳定样本数量的比值作为代价系数,并引入注意力机制,使得模型在判别不稳定样本

收稿日期:2022-11-01;修回日期:2023-06-22

在线出版日期:2023-08-21

基金项目:福建省自然科学基金资助项目(2022J01113)

Project supported by the Natural Science Foundation of Fujian Province(2022J01113)

时考虑相邻节点特征的相关性,从而在提高模型不稳定样本准确率的同时保持较高的模型全局准确率。

对于电力系统暂态稳定评估中存在的样本不平衡问题,本文提出基于样本梯度范数的电力系统暂态稳定评估模型的代价敏感修正方法。为了综合考虑样本数量和样本质量对模型的影响,本文从评估模型的训练过程出发,提出基于梯度范数均值比的量化训练样本不平衡程度的方法。基于此,构建代价敏感系数矩阵,修正模型损失函数,再训练得到最终的暂态稳定评估模型。本文提出的方法能够有效解决训练样本不平衡带来的评估倾向性问题,并提升全局准确率。

1 不平衡处理算法

1.1 传统代价敏感法

传统代价敏感法从样本的先验概率分布出发,认为样本的先验概率分布和不稳定样本数量与稳定样本数量的比值相同,因此将不稳定样本数量与稳定样本数量的比值,即样本数量比作为代价系数。实际上,不稳定样本和稳定样本的概率分布是不同的,因此,采用样本数量比量化不平衡程度不够准确。在电力系统暂态稳定评估中,每个样本的系统运行状态和故障情况存在差异,故障严重程度不同,模型对故障严重程度高的样本的拟合程度高于故障严重程度低的样本。一般情况下,不稳定样本和稳定样本的故障严重程度的分布不同,即样本质量存在不平衡问题,这导致模型对2类样本的拟合程度也存在差异,因此,模型评估倾向性还受到样本质量不平衡的影响。

1.2 梯度范数

为了综合考虑样本数量和质量对暂态稳定评估模型的影响,可以通过样本后验分布信息衡量样本的不平衡程度^[19],样本后验分布信息比先验信息能更准确地反映样本的不平衡情况。由于影响模型参数更新的是损失函数的梯度,采用样本损失值作为后验分布信息并不准确,因此,本文从暂态稳定评估模型的训练过程出发,推导出能更准确反映样本不平衡程度的后验分布信息。

训练深度学习模型的目的是通过最小化损失函数求解模型的最优参数。针对电力系统暂态稳定评估问题,本文采用二分类交叉熵损失函数,如式(1)所示。

$$L(y_i, \mathbf{x}_i) = -\frac{1}{N} \sum_{i=1}^N [y_i \ln H_\theta(\mathbf{x}_i) + (1-y_i) \ln (1-H_\theta(\mathbf{x}_i))] \quad (1)$$

式中: $L(y_i, \mathbf{x}_i)$ 为二分类交叉熵损失函数, $\mathbf{x}_i$ 为训练集中的第*i*个样本, y_i 为样本 $\mathbf{x}_i$ 的真实标签; N 为训练

样本数量; $H_\theta(\mathbf{x}_i)$ 为模型对样本 $\mathbf{x}_i$ 的评估结果。

训练深度学习模型是通过优化算法解决模型损失函数的最小化问题,目前模型优化算法包括随机梯度下降(stochastic gradient descent, SGD)、自适应梯度优化和自适应矩估计^[22-23]。本文采用SGD求解模型的最优参数,如式(2)所示。

$$\theta' = \theta - \varepsilon \nabla_\theta L(y_i, \mathbf{x}_i) \quad (2)$$

式中: θ, θ' 分别为模型更新前、后的参数; ε 为学习率。

由式(2)可知,损失函数的梯度决定了模型参数的更新方向和大小。损失函数的梯度可以通过式(3)计算得到。

$$\nabla_\theta L(y_i, \mathbf{x}_i) = \frac{\partial L(y_i, \mathbf{x}_i)}{\partial \theta} = \frac{\partial L(y_i, \mathbf{x}_i)}{\partial H_\theta(\mathbf{x}_i)} \frac{\partial H_\theta(\mathbf{x}_i)}{\partial \theta} \quad (3)$$

将式(1)代入式(3)可得:

$$\nabla_\theta L(y_i, \mathbf{x}_i) = \begin{cases} -\frac{1}{H_\theta(\mathbf{x}_i)} \frac{\partial H_\theta(\mathbf{x}_i)}{\partial \theta} & y_i = 1 \\ -\frac{1}{1-H_\theta(\mathbf{x}_i)} \frac{\partial H_\theta(\mathbf{x}_i)}{\partial \theta} & y_i = 0 \end{cases} \quad (4)$$

对于最简单的神经网络而言, $H_\theta(\mathbf{x}_i) = \sigma(\mathbf{x}_i)$,其中 $\sigma(\cdot)$ 为Sigmoid函数,因此,式(4)可简化为式(5)。

$$\nabla_\theta L(y_i, \mathbf{x}_i) = \begin{cases} H_\theta(\mathbf{x}_i) - 1 & y_i = 1 \\ H_\theta(\mathbf{x}_i) & y_i = 0 \end{cases} \quad (5)$$

因此,本文定义梯度范数*G*为:

$$G = |H_\theta(\mathbf{x}_i) - y_i| \quad (6)$$

*G*表示一个样本的属性,并表明该样本对全局梯度的影响。对于故障严重程度较高的样本,在训练过程中,该样本的梯度范数较小,对模型的影响较小,模型更容易预测准确,因此,梯度范数*G*能够反映该样本对评估模型参数的影响。为了避免暂态稳定评估模型在训练过程中的过拟合问题,本文从原始数据集中抽取部分样本构成验证集,计算验证集中稳定样本的总梯度 G_s 和不稳定样本的总梯度 G_u ,分别如式(7)、(8)所示。

$$G_s = \sum_{r=1}^{N'_s} |H_\theta(\mathbf{x}_r) - 1| \quad (7)$$

$$G_u = \sum_{z=1}^{N'_u} |H_\theta(\mathbf{x}_z)| \quad (8)$$

式中: $\mathbf{x}_r$ 为验证集中的第*r*个稳定样本; $\mathbf{x}_z$ 为验证集中的第*z*个不稳定样本; N'_s, N'_u 分别为验证集中的稳定样本数量和不稳定样本数量。

模型对某类样本的拟合程度体现在验证集中该类样本的梯度范数均值,梯度范数均值越小,表明模型对该类样本的拟合程度越高。相较于损失函数均值比,梯度范数均值能更准确地反映模型样本的拟合情况。因此,本文通过计算验证集中不稳定样本

和稳定样本的梯度范数均值比 G_{imb} 衡量模型的评估倾向性,如式(9)所示。

$$G_{imb} = \frac{G_u N'_s}{G_s N'_u} \quad (9)$$

计算得到数据集的不平衡程度后,将其作为损失函数的修正系数来修正模型的倾向性,如式(10)所示。

$$L(y_i, x_i) = -\frac{1}{N} \sum_{i=1}^N [y_i \ln H_\theta(x_i) + G_{imb}(1-y_i) \ln(1-H_\theta(x_i))] \quad (10)$$

2 基于SSAE的暂态稳定评估模型

本文基于SSAE模型构建电力系统暂态稳定评估模型,SSAE由多个稀疏自编码器堆叠而成。稀疏自编码器是一种无监督模型,通过编码和解码来学习输入信息的低维表示,但由于结构较浅,稀疏自编码器无法获得更深层的数据特征,SSAE将多个稀疏自编码器进行叠加,有效提高了特征提取能力。SSAE的训练过程包括无监督的预训练和有监督的模型参数微调2个阶段。首先,对每个稀疏自编码器进行单独的无监督预训练,并为下一阶段提供良好的初始参数,从而提高模型训练速度和评估精度;然后,将所有预训练的稀疏自编码器依次堆叠,并利用反向传播算法对整个网络进行有监督的微调,从而进一步增强模型的性能。电力系统暂态稳定评估模型的评估倾向性问题本质上是模型对稳定样本的过拟合问题,由于SSAE引入了稀疏约束,模型具有较好的泛化性能,这能在一定程度上抑制模型的过拟合情况。本文以SSAE为例构建电力系统暂态稳定评估模型,并在此基础上进一步解决模型的评估倾向性问题。

值得一提的是,本文提出的模型评估倾向性修正方法不仅适用于SSAE,还适用于其他深度学习模型。

3 暂态稳定评估模型的建立

3.1 暂态稳定评估流程

本文提出的电力系统暂态稳定评估流程包括离线训练和在线应用,具体步骤如下。

1)选择功角和角速度偏差作为样本集特征。利用仿真数据构建训练集,将故障清除前、故障清除时刻、故障清除1个周期后和故障清除2个周期后这4个时间点的系统运行信息作为每个样本的特征。

2)根据暂态稳定结果对每个样本进行标签标记。本文利用暂态稳定指数^[24]判断样本的暂态稳定结果,如式(11)所示。

$$T_1 = \frac{360 - |\Delta\delta_{\max}|}{360 + |\Delta\delta_{\max}|} \quad (11)$$

式中: T_1 为样本暂态稳定指数; $\Delta\delta_{\max}$ 为最大功角差。当 $T_1 \geq 0$ 时,认为系统稳定,否则,认为系统不稳定。

3)标签标记后的仿真生成的样本可以用于构造训练集和验证集。输入训练集,预训练基于SSAE的暂态稳定评估模型,根据式(7)~(9)计算预训练模型的 G_{imb} 。

4)基于 G_{imb} 构建代价敏感系数矩阵,修正模型的损失函数,如式(10)所示,再重新训练基于SSAE的暂态稳定评估模型。

5)在暂态稳定评估模型离线训练完成后,将模型配置在控制中心,通过广域测量系统得到电力系统实时响应数据,模型可以通过实时数据输出暂态稳定性的评估结果。

3.2 暂态稳定评估模型性能指标

本文采用不稳定样本预测错误率、稳定样本预测错误率和模型全局准确率对模型性能进行评价。

不稳定样本预测错误率 P_{FU} 为:

$$P_{FU} = \frac{F_u}{T_u + F_u} \quad (12)$$

式中: F_u 为预测错误的不稳定样本数量; T_u 为预测正确的不稳定样本数量。

稳定样本预测错误率 P_{FS} 为:

$$P_{FS} = \frac{F_s}{T_s + F_s} \quad (13)$$

式中: F_s 为预测错误的稳定样本数量; T_s 为预测正确的稳定样本数量。

评估模型的全局准确率 P_{ACC} 为:

$$P_{ACC} = \frac{T_s + T_u}{T_s + F_s + F_u + T_u} \quad (14)$$

4 算例分析

4.1 IEEE 39节点系统

本节选取IEEE 39节点系统作为测试系统,该系统由39条母线、10台发电机、19个负荷和34条输电线路组成,系统频率为60 Hz。假定相量测量单元部署在系统中的所有发电机组上。除了线路16-19因故障切断后会导致系统解网而不被选择为故障线路外,其余33条输电线路均被选择为故障线路。电力系统的运行状态包括90%、95%、100%、105%、110%的系统容量这5个负荷等级。设置在各故障线路长度的10%、50%、90%位置发生三相短路故障,在故障后的0.1~0.2 s切除故障。最长仿真时长为4 s,采样频率为每秒120次。系统共生成9440个样本,其中包括6416个稳定样本和3024个不稳定样本。

4.1.1 实验参数设置

基于SSAE验证本文方法的有效性。SSAE的各层神经元数量分别为100、50、25个,并以神经元数量为1个的全连接层作为最后的分类层,激活函数为Sigmoid。预训练100次,微调200次。将 L_1 正则化系数设置为0.0001, L_2 正则化系数设置为0.00001。优化器选择SGD,将其学习率设置为0.5。

为了验证模型的泛化能力,从9440个数据中随机抽样选取样本构建训练集、验证集和测试集。训练集用于模型训练,验证集用于计算预训练模型的后验信息,测试集用于评价模型的性能。此外,为了验证本文方法的有效性,对各种不平衡样本比例的训练集进行仿真测试,定义训练集中不稳定样本与稳定样本的数量比 λ ,如式(15)所示。

$$\lambda = \frac{N_u}{N_s} \quad (15)$$

式中: N_u 为训练集中不稳定样本数量; N_s 为训练集中稳定样本数量。

将 λ 的值分别设置为1666:5000、1000:5000和625:5000,生成3种不平衡样本比例的训练集,以测试本文方法的修正效果。验证集中不稳定样本与稳定样本的数量比均为100:100,测试集中不稳定样本与稳定样本的数量比均为1000:1000。

4.1.2 不同不平衡修正方法的比较

本节基于SSAE对比几种不同的数据不平衡修正方法,包括随机欠采样(random under-sampling, RUS)^[12]、随机过采样(random oversampling, ROS)、合成少数过采样(synthetic minority oversampling technique, SMOTE)、自适应合成采样(adaptive synthetic sampling, ADASYN)^[13-14]、基于先验分布的传统代价敏感法^[17]、基于后验信息的代价敏感法^[19]以及本文方法,并测试不同不平衡情况下的评估结果。为避免样本采样带来的随机性误差,生成4个随机种子,分别构建数据集进行测试,取其平均值作为最终结果,如表1以及附录A表A1、A2所示。

表1 $\lambda=1666:5000$ 下不同不平衡修正方法的测试结果

Table 1 Test results of different imbalance correction methods with $\lambda=1666:5000$

修正方法	$P_{ACC} / \%$	$P_{FU} / \%$	$P_{FS} / \%$
无修正	96.21	6.00	1.58
RUS	95.51	4.02	4.95
ROS	97.36	2.40	2.87
SMOTE	97.22	3.00	2.55
ADASYN	97.36	1.60	3.68
传统代价敏感法	97.21	2.45	3.12
基于后验信息的代价敏感法	97.27	2.22	3.22
本文方法	97.44	2.02	3.10

由表1以及表A1、A2可知:训练集的样本不平衡程度越高,模型评估倾向性越明显;经过各种方法修正后,模型的评估偏差均有不同程度的改善;RUS通过随机剔除稳定样本使训练集平衡,但是随机采样可能会丢失训练集中的关键信息,因此,当 $\lambda=1666:5000$ 时,RUS的全局准确率低于未修正的模型;ROS和SMOTE都是随机挑选训练集中的不稳定样本来生成新的不稳定样本,忽略了样本的空间分布情况,模型性能提升效果有限;ADASYN生成更多难以分类的不稳定样本,不仅可以改善原始训练集样本不平衡带来的评估倾向性,还可以自适应地将决策边界转移到难以学习的不稳定样本,大幅降低了不稳定样本的预测错误率,但容易受到离群值的影响,出现模型对不稳定样本的过拟合现象,使稳定样本的错误率急剧上升;传统代价敏感法的准确率高于采样法,但仍存在评估偏差问题;基于后验信息的代价敏感法综合考虑了样本数量和空间分布的不平衡,修正后的模型性能比传统代价敏感法更优越;相较于损失函数均值比,本文方法的梯度范数均值比更能准确反映样本集的不平衡程度,因此,在这些不平衡修正方法中本文方法的模型评估倾向性修正效果最好。

4.1.3 不平衡修正方法的适应性分析

为了验证本文方法的适应性,在IEEE 39节点系统中分别测试基于堆叠自编码器(stack auto-encoder, SAE)、堆叠变分自编码器(stack variational auto-encoder, SVAE)^[15]、堆叠降噪稀疏自编码器(stacked denoising sparse auto-encoder, SSDAE)^[25]、CNN和LSTM的暂态稳定评估模型经本文方法修正后的效果。基于SAE的暂态稳定评估模型的网络参数设置与本文SSAE的一致;基于CNN的暂态稳定评估模型网络参数根据文献[7]进行设置;基于SVAE的暂态稳定评估模型参数根据文献[15]进行设置;基于SSDAE的暂态稳定评估模型参数根据文献[25]进行设置;基于LSTM的暂态稳定评估模型由1层LSTM层和1层全连接层组成。SAE、CNN、SVAE、SSDAE和LSTM均选择SGD优化器,其学习率均设置为0.1。训练集中 λ 设置为1000:5000,验证集中不稳定样本和稳定样本的数量比为100:100,测试集中不稳定样本和稳定样本的数量比为1000:1000。为避免样本采样带来的随机性误差,随机构建3组数据集进行测试,取其平均值作为最终结果,如表2所示。

由表2可知,在5种深度学习方法经本文方法修正后,不稳定样本预测错误率均显著下降,全局准确率提升明显。本文方法从暂态稳定评估模型的训练过程出发,量化样本在训练过程中对模型参数修正

表2 利用本文方法修正不同暂态稳定评估模型的测试结果

Table 2 Test results of different transient stability assessment models corrected by proposed method

暂态稳定评估模型	$P_{ACC} / \%$	$P_{FU} / \%$	$P_{FS} / \%$
SAE	94.11	10.81	0.97
本文方法+SAE	96.69	3.24	3.37
SVAE	95.56	6.47	2.13
本文方法+SVAE	97.35	2.34	2.87
SSDAE	95.98	6.34	1.70
本文方法+SSDAE	96.91	3.10	3.07
CNN	96.21	6.54	1.03
本文方法+CNN	96.65	3.14	3.57
LSTM	94.61	9.58	1.20
本文方法+LSTM	97.40	2.47	2.73

的梯度范数,综合考虑样本数量和质量对不平衡的影响,因此,经本文方法修正后,5种深度学习评估模型均获得了较好的修正效果。

4.2 华东电网系统

为了验证本文提出的电力系统暂态稳定评估模型的实用性,以华东电网系统为例进行测试。该系统共有705台发电机、6040条10~1000 kV电压等级母线和5599条输电线路;系统总容量为30514 MW;系统频率为50 Hz;负荷水平为系统容量的100%;假定相量测量单元部署在200 MW以上的发电机组上。选取500 kV和1000 kV电压等级的597条线路作为故障线路。模拟3种不同类型故障:在三相短路下切断一回线造成的N-1故障;在三相短路和两相接地短路下切断两回线造成的N-2故障。在故障后的0.1~0.2 s切除故障,最长仿真时长为5 s,采样频率为每秒100次。

该电力系统共生成35211个样本,其中包括29203个稳定样本和6008个不稳定样本。随机抽取18000个样本构成训练集,1000个样本构成验证集,6000个样本构成测试集。将 λ 设置为3000:15000,验证集和测试集中不稳定样本与稳定样本的数量比分别为500:500、3000:3000。对比ADASYN、传统代价敏感法、基于后验信息的代价敏感方法和本文方法的不平衡修正效果,为避免随机抽样产生的误差,分别构建3组数据集进行测试,取其结果平均值作为最终结果,结果如表3所示。

表3 华东电网系统中不同不平衡修正方法的测试结果

Table 3 Test results of different imbalanced correction methods in East China Power System

修正方法	$P_{ACC} / \%$	$P_{FU} / \%$	$P_{FS} / \%$
无修正	96.09	6.38	1.43
ADASYN	97.08	2.95	2.90
传统代价敏感法	97.31	2.72	2.67
基于后验信息的代价敏感法	97.41	2.65	2.53
本文方法	97.48	2.50	2.53

与IEEE 39节点系统的实验结果相比,在华东电网系统中,暂态稳定评估模型的精度有所降低。由表3可知:虽然ADASYN在一定程度上改善了样本的不平衡性,但经代价敏感法修正后的模型全局准确率均高于ADASYN,这是由于ADASYN存在过拟合问题;传统代价敏感法仅关注样本数量的不平衡,忽略了样本质量的不平衡,这导致模型的评估倾向性依然存在;基于后验信息的代价敏感法和本文方法综合考虑了样本数量和样本质量的不平衡,但本文方法更准确,即使在大规模电力系统下,在这些修正方法中本文方法也具有最高的总体准确率以及最好的模型评估倾向性修正效果。

5 结论

为了解决电力系统中样本不平衡造成的暂态稳定评估偏差问题,本文提出一种基于梯度范数的暂态稳定评估模型的不平衡修正方法。由于训练集中不稳定样本和稳定样本的数量存在差异,模型对2类样本的拟合程度不同,本文从暂态稳定评估模型的训练过程出发,推导出梯度范数这一样本属性,它反映了模型对样本的拟合程度,相较于损失函数均值比,梯度范数均值比能够更准确地量化模型的不平衡程度,综合考虑了样本数量和质量对模型评估倾向性的影响。此外,本文方法能够在不破坏样本集空间分布的基础上,仅通过修正样本权重改善模型的评估倾向性。在IEEE 39节点系统和华东电网系统的仿真测试结果表明,对于不同不平衡程度的样本集,本文方法的模型评估倾向性修正效果最好,且模型的全局准确率最高。

附录见本刊网络版(<http://www.epae.cn>)。

参考文献:

- [1] GUPTA A, DOOLLA S, CHATTERJEE K. Hybrid AC-DC micro-grid: systematic evaluation of control strategies[J]. IEEE Transactions on Smart Grid, 2018, 9(4): 3830-3843.
- [2] GITIZADEH M, AGHAEI J. Dynamic security consideration in multiobjective electricity markets[J]. Applied Soft Computing Journal, 2014, 16: 1-9.
- [3] FAN H, CHEN Y, HUANG S W, et al. Post-fault transient stability assessment based on k -nearest neighbor algorithm with mahalanobis distance[C]//2018 International Conference on Power System Technology (POWERCON). Guangzhou, China: IEEE, 2018: 4417-4423.
- [4] 王彤, 刘九良, 朱劭璇, 等. 基于随机森林的电力系统暂态稳定评估与紧急控制策略[J]. 电网技术, 2020, 44(12): 4694-4701. WANG Tong, LIU Jiuliang, ZHU Shaoxuan, et al. Transient stability assessment and emergency control strategy based on random forest in power system[J]. Power System Technology, 2020, 44(12): 4694-4701.
- [5] 鲍颜红, 冯长有, 任先成, 等. 基于支持向量机的在线暂态稳定故障筛选[J]. 电力系统自动化, 2019, 43(22): 52-58. BAO Yanhong, FENG Changyou, REN Xiancheng, et al. On-line transient stability fault screening based on support vec-

- tor machine[J]. Automation of Electric Power Systems, 2019, 43(22):52-58.
- [6] 赵慧敏, 帅智康, 沈阳, 等. 基于深度学习的多虚拟同步机微电网在线暂态稳定评估方法[J]. 电力系统自动化, 2022, 46(9): 109-117.
ZHAO Huimin, SHUAI Zhikang, SHEN Yang, et al. Online transient stability assessment method for microgrid with multiple virtual synchronous generators based on deep learning[J]. Automation of Electric Power Systems, 2022, 46(9): 109-117.
- [7] HOU J X, XIE C, WANG T Y, et al. Power system transient stability assessment based on voltage phasor and convolution neural network[C]//2018 IEEE International Conference on Energy Internet (ICEI). Beijing, China: IEEE, 2018: 247-251.
- [8] 张亮, 安军, 周毅博. 基于时间卷积和图注意力网络的电力系统暂态稳定评估[J]. 电力系统自动化, 2023, 47(7): 114-122.
ZHANG Liang, AN Jun, ZHOU Yibo. Transient stability assessment of power system based on temporal convolution and graph attention network[J]. Automation of Electric Power Systems, 2023, 47(7): 114-122.
- [9] 李福成, 徐箭, 廖思阳, 等. 基于样本关注度和多层次特征的多阶段电力系统暂态稳定评估[J]. 中国电机工程学报, 2021, 41(22): 7596-7608.
LI Fucheng, XU Jian, LIAO Siyang, et al. Multi-stage power system transient stability assessment based on sample attention and hierarchical features[J]. Proceedings of the CSEE, 2021, 41(22): 7596-7608.
- [10] 房佳姝, 刘崇茹, 苏晨博, 等. 基于自注意力Transformer编码器的多阶段电力系统暂态稳定评估方法[J/OL]. 中国电机工程学报. [2023-04-17]. <http://kns.cnki.net/kcms/detail/11.2107.TM.20220831.1403.009.html>.
- [11] 赵冬梅, 王闯, 谢家康, 等. 考虑惯量中心频率偏移的自编码器暂态稳定评估[J]. 电网技术, 2022, 46(2): 662-670.
ZHAO Dongmei, WANG Chuang, XIE Jiakang, et al. Transient stability assessment of auto encoder considering frequency shift of inertia center[J]. Power System Technology, 2022, 46(2): 662-670.
- [12] 崔宇, 侯慧娟, 苏磊, 等. 考虑不平衡案例样本的电力变压器故障诊断方法[J]. 高电压技术, 2020, 46(1): 33-41.
CUI Yu, HOU Huijuan, SU Lei, et al. Fault diagnosis method for power transformer considering imbalanced class distribution[J]. High Voltage Engineering, 2020, 46(1): 33-41.
- [13] SANER C B, KESICI M, YASLAN Y, et al. Improving the performance of transient stability prediction using resampling methods[C]//2019 11th International Conference on Electrical and Electronics Engineering (ELECO). Bursa, Turkey: IEEE, 2019: 146-150.
- [14] 谢桦, 陈俊星, 赵宇明, 等. 基于SMOTE和决策树算法的电力变压器状态评估知识获取方法[J]. 电力自动化设备, 2020, 40(2): 137-142.
XIE Hua, CHEN Junxing, ZHAO Yuming, et al. Knowledge acquisition method of power transformer condition assessment based on SMOTE and decision tree algorithm[J]. Electric Power Automation Equipment, 2020, 40(2): 137-142.
- [15] 王怀远, 陈启凡. 基于代价敏感堆叠变分自动编码器的暂态稳定评估方法[J]. 中国电机工程学报, 2020, 40(7): 2213-2220, 2400.
WANG Huaiyuan, CHEN Qifan. A transient stability assessment method based on cost-sensitive stacked variational auto-encoder[J]. Proceedings of the CSEE, 2020, 40(7): 2213-2220, 2400.
- [16] 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 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.
- [17] NG W W Y, ZHANG J J, LAI C S, et al. Cost-sensitive weighting and imbalance-reversed bagging for streaming imbalanced and concept drifting in electricity pricing classification[J]. IEEE Transactions on Industrial Informatics, 2019, 15(3): 1588-1597.
- [18] 高国强, 杨飞豹, 尹豪杰, 等. 基于代价敏感组合核相关向量机的电力变压器故障诊断[J]. 电测与仪表, 2017, 54(16): 7-13.
GAO Guoqiang, YANG Feibao, YIN Haojie, et al. Transformer fault diagnosis based on cost-sensitive multi-kernel learning relevance vector machine[J]. Electrical Measurement & Instrumentation, 2017, 54(16): 7-13.
- [19] 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 method of SSAE transient stability assessment model based on posterior distribution information[J]. Electric Power Automation Equipment, 2022, 42(3): 135-141.
- [20] 钟智, 管霖, 苏寅生, 等. 基于图注意力深度网络的电力系统暂态稳定评估[J]. 电网技术, 2021, 45(6): 2122-2130.
ZHONG Zhi, GUAN Lin, SU Yinsheng, et al. Power system transient stability assessment based on graph attention deep network[J]. Power System Technology, 2021, 45(6): 2122-2130.
- [21] 杜一星, 胡志坚, 陈纬楠, 等. 基于改进CatBoost的电力系统暂态稳定评估方法[J]. 电力自动化设备, 2021, 41(12): 115-122.
DU Yixing, HU Zhijian, CHEN Weinan, et al. Transient stability assessment method of power system based on improved CatBoost[J]. Electric Power Automation Equipment, 2021, 41(12): 115-122.
- [22] 史加荣, 王丹, 尚凡华, 等. 随机梯度下降算法研究进展[J]. 自动化学报, 2021, 47(9): 2103-2119.
SHI Jiarong, WANG Dan, SHANG Fanhua, et al. Research advances on stochastic gradient descent algorithms[J]. Acta Automatica Sinica, 2021, 47(9): 2103-2119.
- [23] 郭春明, 任继红. 基于XGBoost-EE的电力系统暂态稳定评估方法[J]. 电力自动化设备, 2021, 41(2): 138-143, 152.
WU Chunming, REN Jihong. Power system transient stability assessment method based on XGBoost-EE[J]. Electric Power Automation Equipment, 2021, 41(2): 138-143, 152.
- [24] WANG H Y, CHEN Q F, ZHANG B H. Transient stability assessment combined model framework based on cost-sensitive method[J]. IET Generation, Transmission & Distribution, 2020, 14(12): 2256-2262.
- [25] WANG H Y, YE W T. Transient stability evaluation model based on SSDAE with imbalanced correction[J]. IET Generation, Transmission & Distribution, 2020, 14(11): 2209-2216.

作者简介:

胡力涛(1998—),男,硕士研究生,主要研究方向为电力系统运行与控制(E-mail: 651976154@qq.com);

王怀远(1987—),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(E-mail: 79749544@qq.com);

党然(1991—),男,主要研究方向为人工智能算法(E-mail: 584310203@qq.com);

童浩轩(1998—),男,主要研究方向为电力系统运行与控制(E-mail: 1085342102@qq.com);

张旸(1989—),男,讲师,博士,主要研究方向为新型电力系统稳定性分析(E-mail: yangzhang@fzu.edu.cn)。

(编辑 王锦秀)

(下转第177页 continued on page 177)

Short-term power load forecasting based on improved Autoformer model

FAN Xingrui, LI Yuancheng

(College of Control and Computer Engineering, North China Electric Power University, Beijing 102206, China)

Abstract: Aiming at the low accuracy problem of short-term power load forecasting caused by the influence of multiple uncertain factors such as weather, temperature and holiday, a short-term power load forecasting model based on an improved Autoformer model is proposed. By changing the pre-processing convention of sequence decomposition, an internal decomposition module of depth model is designed, which extracts the intrinsically complex time series trend of hidden state in the model, and makes the model have the ability to decompose complex time series asymptotically. The Nystrom self-Attention mechanism is proposed, which uses the Nystrom method to approximate the standard self-Attention mechanism. The experimental results of power load forecasting in a region show that the proposed model has lower time complexity and higher accuracy than the standard Autoformer model.

Key words: short-term power load forecasting; timing decomposition module; Nystrom self-Attention mechanism; Sdformer model

(上接第 163 页 continued from page 163)

Imbalance correction method of transient stability assessment model based on gradient norm

HU Litao¹, WANG Huaiyuan¹, DANG Ran², TONG Haoxuan³, ZHANG Yang¹

(1. Fujian Key Laboratory of New Energy Generation and Power Conversion, College of Electrical Engineering and Automation, Fuzhou University, Fuzhou 350116, China;

2. Shaanxi Aircraft Industry Limited Liability Company, Hanzhong 723000, China;

3. Taining County Power Supply Branch of State Grid Fujian Electric Power Co., Ltd., Sanming 354400, China)

Abstract: In order to solve the problem of transient stability assessment deviation caused by the imbalance of power system sample quantity and quality, starting from the training process of assessment model, the gradient norm of samples to model parameters is obtained by the pre-training model, and the mean ratio of gradient norm is introduced to quantify the imbalance of samples. Compared with the prior information, the mean ratio of gradient norm comprehensively considers the imbalance between the sample quantity and quality. An imbalanced correction method based on the cost-sensitive method is proposed, which is used to improve the assessment preference of the model and realize a preferable correction effect. The simulative results of IEEE 39-bus system and East China Power System verify the effectiveness of the proposed method.

Key words: deep learning; transient stability assessment; cost-sensitive; gradient norm; stacked sparse auto-encoder; imbalanced sample

附录 A:

表 A1 $\lambda=1000:5000$ 下不同修正方法的测试结果
Table A1 Test results of different correction methods with
 $\lambda=1000:5000$

修正方法	$P_{ACC}/\%$	$P_{FU}/\%$	$P_{FS}/\%$
无修正	94.32	10.76	0.60
RUS	95.71	3.20	5.38
ROS	97.04	3.05	2.88
SMOTE	96.57	4.10	2.75
ADASYN	96.86	2.43	3.85
传统代价敏感法	97.05	3.25	2.65
基于后验信息的代价敏感法	96.77	2.10	4.35
本文方法	97.17	1.83	3.82

表 A2 $\lambda=625:5000$ 下不同修正方法的测试结果
Table A2 Test results of different correction methods with
 $\lambda=625:5000$

修正方法	$P_{ACC}/\%$	$P_{FU}/\%$	$P_{FS}/\%$
无修正	92.78	14.12	0.325
RUS	95.64	2.65	6.08
ROS	97.15	2.85	2.85
SMOTE	96.80	4.08	2.32
ADASYN	96.60	3.50	3.30
传统代价敏感法	97.25	2.85	2.65
基于后验信息的代价敏感法	97.28	2.10	3.35
本文方法	97.40	2.02	3.18