

考虑样本分布不均衡的电力系统暂态稳定 自适应评估

姬凯旋, 乔骥, 赵紫璇, 赵津蔓, 史梦洁, 杨帆

(中国电力科学研究院有限公司, 北京市 海淀区 100192)

Adaptive Assessment of Transient Stability of Power Systems Considering Unbalanced Sample Distribution

Ji Kaixuan, Qiao Ji, Zhao Zixuan, Zhao Jinman, Shi Mengjie, Yang Fan

(China Electric Power Research Institute, Haidian District, Beijing 100192, China)

ABSTRACT: Data-driven methods for transient stability assessment can quickly and accurately evaluate the transient stability of power systems. However, they still face the challenges of data imbalance and insufficient generalization capabilities in scenarios with small or weak samples. This paper proposes an adaptive assessment framework for transient stability that combines Generative Adversarial Graph Networks (GAGN) with active transfer learning to address these issues. To tackle the imbalance in the sample distribution within power systems, we have designed a data augmentation algorithm based on GAGN. This algorithm constructs the state quantities of each component in the power system and their topological relationships into graph data. Collaboration with the generator and the graph attention discriminator produces unstable data to assist in model training, effectively improving the model's accuracy in identifying imbalanced samples. To enhance the model's generalization ability in new scenarios and to achieve rapid model updating, this paper introduces an active transfer learning strategy for updating model parameters. High-quality samples are selected using an entropy uncertainty method, and the model parameters are updated through fine-tuning. The effectiveness and practicality of the proposed methods have been validated on the IEEE 39-node system, improving model adaptability while reducing update costs.

KEY WORDS: transient stability assessment; generative adversarial graph network; active learning; transfer learning

摘要: 数据驱动的暂态稳定评估方法能快速准确评估电力系统稳定性,但在小样本或弱样本情况下,仍然面临数据不均衡和泛化能力不足的问题。为了解决该问题,该文提出了一种联合生成对抗图网络(graph networks, GAGN)与主动迁移

学习的暂态稳定自适应评估框架。针对电力系统中样本分布的不均衡性,该文设计了一种基于生成对抗图网络的数据增强算法,将电力系统中各元件状态量及其拓扑关联关系构建为图数据,并通过生成器和图注意力判别器的协作,生成失稳数据辅助模型训练,有效提高模型对不均衡样本辨识的准确率。为了增强模型在新场景下的泛化能力,实现模型快速更新,该文提出一种主动迁移学习策略,用于更新模型参数。通过熵不确定性方法挑选高质量样本,并通过微调更新模型参数。在IEEE 39节点系统上验证了所提方法的有效性和实用性,在提高模型适应性的同时降低了更新成本。

关键词: 暂态稳定评估; 生成对抗图网络; 主动学习; 迁移学习

DOI: 10.13335/j.1000-3673.pst.2024.0812

0 引言

暂态稳定评估是电力系统安全稳定分析的重要内容^[1-2]。随着可再生能源的大规模并网,电力系统的灵活性和复杂性呈递增趋势。传统电力系统暂态稳定评估方法计算量大,计算效率低的缺点日益凸显,无法满足高效评估的要求。高效、准确的暂态稳定评估方法已成为当前领域研究重点^[3-4]。

随着深度学习、深度强化学习等新一代人工智能技术的发展,数据驱动方法为电力系统暂态稳定研究提供了一个新思路^[5-8]。人工智能技术从数据角度出发,建立电力系统运行特征与暂态稳定结果的映射关系,实现端对端的快速、准确评估^[9-11]。文献[12]提出一种基于数据驱动的在线动态安全分析(dynamic security assessment, DSA)方法,将电力系统暂态问题映射为机器学习中的二分类问题。文献[13]从特征筛选和策略设计两方面建立基于直流潮流的深度学习方法,加快“N-1”校核速度。文献[14]

基金项目: 国家重点研发计划项目(2021YFB2400800)。

Project Supported by the National Key R&D Program of China (2021YFB2400800).

通过互信息和皮尔逊系数筛选特征,采用随机森林算法评估系统的安全性。由于数据驱动方法具有准确率高、计算速度快等优点,人工智能的方法已广泛应用于暂态稳定评估研究中。

然而,考虑到实际电力系统中发生事故的可能性较小,在采用深度学习等人工智能方法时,面临稳定样本和失稳样本数量不均衡问题,进而影响分类器的性能。目前,数据驱动下的暂态稳定评估通常采用等比例采样避免样本不均衡问题,这种情况下模型表达能力不足,易过拟合。为解决这一问题,部分研究者将生成对抗网络(generative adversarial network, GAN)^[15-17]引入到样本不均衡的暂态稳定评估中。文献[18]提出了考虑数据缺失场景基于双生成器对抗生成网络的数据增强算法;文献[19]采用条件生成对抗网络对不稳定样本进行扩充,得到更平衡的训练数据集。考虑到无监督学习 GAN 存在生成样本不可控性的问题,文献[20]将卷积神经网络建立生成对抗网络,提出一种基于改进深度卷积生成对抗网络的数据增强算法。尽管有效提高了生成样本的质量,但实质上并未改变 GAN 生成样本的不可控性特性。为了解决上述问题,本文提出了一种基于生成对抗图网络(graph networks, GAGN)的数据增强算法,利用电力系统拓扑结构信息提升生成样本的质量。

此外,现有数据驱动暂态稳定研究依赖于离线阶段完备的样本库。当电网运行方式或拓扑结构发生较大变化,基于原拓扑建立的模型并不适用,需要重新建立样本库来训练模型。迁移学习是一种利

用已有知识提升新场景下模型性能的机器学习方法^[21-23]。针对泛化性较差的问题,文献[24]利用迁移学习的方法提升模型在新运行工况下的性能。文献[25-26]利用迁移学习中的微调方法提高模型泛化性,在保持模型结构不变的前提下,固定模型的浅层参数,利用模型在源域中学习的知识辅助更新后几层参数,从而减少更新成本。

本文提出了一种联合生成对抗网络、迁移学习和主动学习的电力系统暂态稳定自适应评估框架,旨在解决实际应用时存在的样本不均衡问题。离线阶段通过 GAGN 网络扩充失稳样本,利用拓扑结构信息提升样本生成的可信性,进而提升 DSA 模型性能。在线评估阶段,当电力系统运行工况发生变化时,通过主动迁移策略对模型进行更新,在保证迁移性能的基础上降低了模型更新所需的样本数量,解决了电力系统小样本更新问题。

1 考虑样本分布不均衡的电力系统暂态稳定自适应评估框架

本文提出一种考虑样本分布不均衡的电力系统暂态稳定自适应评估框架。针对暂态稳定评估中稳定样本和失稳样本比例不均衡的问题,在离线阶段生成对抗网络丰富样本库,增加训练数据的丰富性和多样性。针对实际场景和离线样本库数据差异带来的模型泛化性问题,采用主动学习挑选高质量样本辅助更新,并结合迁移学习的微调策略进一步增强模型在新能源工况下的预测性能。模型整体框架如图 1 所示。




图 1 整体框架

Fig. 1 Overall framework

1.1 样本集构造

根据《电力系统安全稳定控制技术导则》, DSA 要求电网具备对特定事件的承受能力。在实际操作

中,通常将这种可承受事件的持续时间设定为 0.1s 的故障。为保证数据的全面性,本文在考虑风电和光伏机组的输出波动基础上,通过改变相应的火电

机组比例, 对所有的故障线路进行动态“N-1”校验, 批量仿真生成样本。

考虑到安全域下 DSA 更关注系统的潮流分布情况, 本文采用输电线路的有功功率\无功功率以及节点电压幅值作为模型的输入特征。稳定判别指标选择暂态稳定指数(transient stability index, TSI)

$$\eta = \frac{\pi - |\Delta\delta_{\max}|}{\pi + |\Delta\delta_{\max}|} \quad (1)$$

式中: $\Delta\delta_{\max}$ 为火电机组间的最大功角差; 当 $\eta > 0$ 表示暂态稳定, $\eta \leq 0$ 表示暂态失稳。假设有 n 条线路进行动态“N-1”校验, 则样本标签可表示为

$$\text{label} = \begin{cases} 1, & \bigcap_{i=1}^n (\eta_i > 0) \\ 0, & \text{其他} \end{cases} \quad (2)$$

式中: $\bigcap_{i=1}^n (\eta_i > 0)$ 表示当前运行方式下满足动态“N-1”故障校验的所有线路集合, 若所有线路都满足校验则标签为 1。反之, 若存在一项动态“N-1”校验未通过则为 0。

1.2 基于 CNN 的暂态评估模型

本文提出的暂态稳定自适应评估框架选择 CNN 为基础分类器, CNN 是一种经典的深度学习模型。通过卷积操作和池化操作, CNN 能够显著提高模型对输入数据的特征提取能力。卷积操作使模型能够局部感知输入数据, 捕获局部特征, 而池化操作则有助于减少数据维度并提高模型的计算效率。此外, CNN 的视野共享机制允许模型在不同位置共享权重参数, 从而减少了网络的参数量, 提高了模型的泛化性能。模型结构如图 2 所示。




图 2 CNN 模型结构

Fig. 2 Structure of CNN model

2 基于生成对抗图网络的数据增强

2.1 生成对抗网络算法

生成对抗网络是一种典型的无监督学习算法, 受到博弈论中零和博弈的启发, 生成器 G 和判别器 D 通过相互对弈来提高生成器 G 生成样本的真实性。通过持续的博弈对抗, 生成器能够有效提升样本生成的能力, 并从中学习原始数据的分布特征。博弈过程中的损失函数可定义为

$$\min_G \max_D V(D, G) = E_{x \sim P_{\text{data}}(x)} [\lg D(x)] + E_{z \sim P_z(z)} [\lg(1 - D(G(z)))] \quad (3)$$

式中: E 表示数学期望; x 表示真实数据; 生成器 G 接受的噪声为 z ; $x \sim P_{\text{data}}(x)$ 和 $P_z(z)$ 分别表示真实数据分布和先验噪声分布; $G(z)$ 表示生成器 G 在映射随机噪声 z 后生成的虚假样本; $D(x)$ 表示判别器 D 认为输入数据 x 为真实的概率。 $D(G(z))$ 表示生成的虚假样本 $G(z)$ 被判别器 D 判断为真实的概率。

2.2 图对抗生成网络算法

图神经网络通过节点之间的信息传递和聚合, 学习到包含每个节点邻域信息的状态特征, 图中每个节点会根据其相邻节点的信息来更新自己的表示^[27-30]。令 $\mathbf{x}_v$ 表示节点 v 的特征向量, $\mathbf{x}_{\text{ne},v}$ 、 $\mathbf{x}_{\text{co},v}$ 表示节点 v 的邻接节点特征及所连的边特征, 节点 v 的更新表示为

$$\mathbf{h}_v = f[k(\mathbf{x}_v, \mathbf{x}_{\text{co},v}, \mathbf{x}_{\text{ne},v}, \mathbf{h}_{\text{ne},v})] \quad (4)$$

式中: $f(\cdot)$ 为 softmax 函数, 这种信息聚合机制使得节点能够获取周围节点的相关信息, 从而更好地表征节点的特征。

与传统的 GAN 算法不同, GAGN 可将电力系统中各元件状态量及其拓扑关联关系构建为图数据, 并通过生成器和判别器的协作, 实现电力系统仿真数据的生成和数据质量的提升。生成器用于生成电网元件中的状态量特征, 然后, 生成器生成的节点属性数据被转换为图的形式。在这个过程中, 电网的母线被映射为图数据中的节点, 而支路则被映射为图数据中的边。此外, 电力系统的拓扑结构也被映射为节点和边的邻接矩阵。最后, 判别器将根据生成的电力图数据判断其与增强前的图数据的相似性。模型结构如图 3 所示。




图 3 GAGN 模型结构

Fig. 3 Structure of GAGN model

选择图注意力网络(graph attention networks, GAT)作为判别器的网络结构。GAT 是一种基于空间域的图神经网络, 其图注意力层利用注意力机制来加权聚合邻居节点的特征, 并根据这些信息更新每个节点的状态。

$$\alpha_{v,u}^{(k)} = f(\text{LeakyReLU}(a^T [W^{(k)} \mathbf{h}_v^{(k-1)} \| W^{(k)} \mathbf{h}_u^{(k-1)}])) \quad (5)$$

式中: $\alpha_{v,u}^{(k)}$ 表示为 k 层网络中节点 v 和节点 u 的注意

力系数; LeakyReLU()是神经网络的激活函数。 $W^{(k)}$ 表示 k 层网络中可学习的权重矩阵; $h_v^{(k-1)}$ 表示 $k-1$ 层网络中节点 v 的特征向量; $h_u^{(k-1)}$ 表示 $k-1$ 层网络中节点 u 的特征向量。

第 k 层的卷积层输出可表示为

$$h_v^{(k)} = \sigma \left(\sum_{u \in N(v) \cup v} \alpha_{v,u}^{(k)} W^{(k)} h_u^{(k-1)} \right) \quad (6)$$

GAT 通过使用注意力机制, 允许每个节点根据其与其邻居节点的关系分配不同的权重, 这样可以根据电网的拓扑结构对所有节点的特征进行更新。这种方法有助于在电力系统中提取和增强局部特征, 从而提高对关键节点特性的识别能力。

2.3 数据增强算法评估指标

为避免实验的随机性, 本文采用推土机距离(wasserstein distance, WD)和弗雷歇距离(Fréchet inception distance, FID)作为定量评估指标。这些指标被用来验证基于 GAGN 的数据增强算法所生成样本的多样性和质量。

WD 是衡量两个概率分布之间距离的指标, 主要用于表示两个分布的相似性。相较于传统的 KL(Kullback Leibler, KL) 散度和 JS(Jensen Shannon, JS)散度, WD 具有连续性质, 更适用于度量概率分布的相似性。对于两个概率分布 p_r 和 p_g , 其定义为

$$W(p_r, p_g) = \inf_{\gamma \sim \Pi(P_r, P_g)} E_{(m,n) \sim \gamma} [\|m - n\|] \quad (7)$$

式中: $\Pi(p_r, p_g)$ 表示以 p_r 和 p_g 为边际分布的联合概率分布集合; $\inf$ 表示集合的下确界; E 表示联合概率分布的期望距离; m 和 n 表示两种样本。

FID 用于衡量生成样本和真实样本在特征级别的相似性。其公式为

$$\text{FID}(p_r, p_g) = \|\mu_r - \mu_g\|_2^2 + \text{Tr}[C_r + C_g - 2(C_r C_g)^{1/2}] \quad (8)$$

式中: μ_r 和 μ_g 分别表示通过 Inception V3 网络将生成和真实样本嵌入到特征空间后计算得到的样本均值; C_r 和 C_g 分别表示相应的协方差; Tr 是矩阵的迹。FID 通过计算生成样本和真实样本特征的均值和协方差矩阵之间的 Fréchet 距离, 量化了它们在特征空间中的分布差异。

3 基于主动迁移学习的自适应更新策略

3.1 主动学习原理

主动学习是一种通过选择并标注最有价值的样本来训练模型的方法, 它能够在减少数据标注成本的同时提高模型性能^[31]。这一过程包括 5 个主要

部分: 未标注样本池、查询策略、标注者、标注数据集和目标模型。通过迭代选择样本进行标注, 并将这些新标注的数据集集成到训练集中, 模型会不断更新, 直至达到预设的性能目标。具体的训练流程可以参考图 4 所示的示意图。




图4 主动学习示意图

Fig. 4 Schematic diagram of active learning

查询策略是主动学习中的核心内容, 直接影响挑选样本的质量。熵不确定性查询策略用信息熵量化样本的不确定性, 优先选择信息熵最大(即模糊分类边界附近)的样本。

$$x_M^* = \arg \max_x - \sum_i p(y_i | x) \log_2 p(y_i | x) \quad (9)$$

式中: $p(y_i | x)$ 表示样本 x 属于类别 y_i 的概率, 与其他策略相比, 基于熵不确定性的查询策略能更全面地考虑样本价值, 有助于模型区分不同样本间的分类边界。

3.2 主动迁移学习原理

在 DSA 问题中, 当将事先离线训练好的预测模型应用于在线运行的电力系统时, 面临的主要挑战在于当电力系统的运行方式和拓扑结构变化时, 离线样本库和在线的量测数据样本分布特性难以完全匹配, 出现了模型适应性不足, 预测性能下降的问题。

迁移学习是机器学习领域的一种创新范式, 该方法解决了当训练样本与测试样本数据分布不同时, 人工智能模型在 DSA 场景下预测性能下降的问题。迁移学习的核心思想是当处理新领域(目标域)的问题时, 可以在现有领域(源域)中训练好的模型基础上更新目标域模型, 使得该模型能够根据不同的运行场景自适应的调参, 从而适应不同新场景^[32]。

当系统的拓扑结构和运行方式发生变化时, 需要及时对预测模型进行更新, 否则会导致模型的性能下降。本文采用的主动迁移学习方法主要包括以下 3 个步骤。

1) 参数初始化。采用时域仿真法获得源域的

样本数据集, 利用该样本数据集训练 CNN 模型, 使其获得较好的暂态稳定评估性能, 保存 CNN 模型的网络结构和偏置参数 θ 。利用保存好的参数 θ 初始化目标域模型参数。

2) 冻结浅层权重。固定源域 CNN 模型的前几层网络结构和参数。

3) 微调模型权重。利用主动学习算法挑选高价值数据, 并基于挑选的数据对目标域 CNN 模型进行微调训练, 以获得更好的评估性能。

3.3 电力系统暂态稳定自适应评估流程

考虑样本分布不均衡的暂态稳定自适应评估流程如图 5 所示。该流程主要包括数据增强、离线训练和在线评估 3 个部分。




图 5 电力系统暂态稳定自适应评估流程

Fig. 5 Adaptive assessment process for transient stability of power system

4 实验

4.1 IEEE39 节点系统算例分析

算例采用 IEEE39 节点数据, 仿真软件是电力系统分析综合程序(Power System Analysis Software Package, PSASP), 硬件配置为 Intel(R) Core(TM) i5-10400 CPU2.90GHz/16.0 GB RAM。

4.1.1 样本设置

为了提高仿真样本与实际工况的相似性, 本文将发电机 BUS-32 和 BUS-36 替换为风力发电机, 发电机 BUS-33 替换为 2 型光伏电站, 模拟实际电网中新能源的出力。图 6 为 IEEE39 节点结构。

在潮流模块中采用不同的发电和负荷波动方




图 6 IEEE39 节点结构

Fig. 6 IEEE39 node structure

式来模拟电力系统的运行情况。火电机出力在 80%~120%之间, 并以 20%步长变化, 风电机组和光伏机组出力在 0~80%之间以 20%步长变化。相应调整负荷的比例保证功率平衡, 并使电压维持在 0.95~1.05(标么值)范围内。设置故障持续时间为 0.1s 的三相短路故障, 故障位置为 2%、50%和 98%这 3 种情况。共生成 38352 组样本, 包括 26934 组稳定样本和 11418 组失稳样本。从总样本中随机抽取 10000 条样本作为仿真数据库, 训练集与测试集的比例为 7:3。

4.1.2 模型性能评估

本文选取 4 种典型数据驱动机器学习算法: 支持向量机(support vector machines, SVM)、长短期记忆网络(long short term memory, LSTM)、深度神经网络(deep neural network, DNN)和卷积神经网络(convolutional neural networks, CNN), 其中 SVM 使用线性核, 正则化参数为 1.0。LSTM 中隐藏层单元的数量为 200。DNN 模型包括 4 层全连接层, 每层分别含 64、128、256、2 个神经元。CNN 为 LeNet 结构, 卷积核为 3, 每层卷积层后连接步长为 1 的最大池化层, 还包括两个全连接层和一个输出层。以上算法激活函数均为 Relu。实验结果如表 1 所示, 与深度模型相比, SVM 这种传统机器学习方法的表现较差, 并不适用于暂态稳定评估中, DNN、LSTM 和 CNN 等深度学习模型能够更好地捕捉数据中的复杂关系。CNN 的准确率(Acc)、精准率(Prec)、召回率(Rec)和 F1 分数(F1)各项指标均达到 97%, 这表明 CNN 能够更好地捕获暂态过程中的数据空间特征, 相较于 DNN 和 LSTM, CNN 具有更好的学习能力。各模型评估性能见表 1。

表 1 模型评估性能
Table 1 Model evaluation performance

模型	Acc/%	Pre/%	Rec/%	F1/%
DNN	96.16	96.24	96.13	96.13
LSTM	95.53	95.61	95.52	95.53
CNN	97.63	97.65	97.62	97.63
SVM	94.92	95.04	94.83	94.92

4.1.3 特征集选择

考虑到安全域下的暂态稳定分析更关注系统的潮流分布情况,本文采用稳态特征作为模型的输入特征。当前的特征选择主要为数据挖掘选择和人工经验选择两种方法,数据挖掘选择特征时,通常依靠某一度量标准挑选出在该准则下分数靠前的特征形成特征子集。但这种选择方式过分依赖度量标准与寻优算法,容易忽略变量之间的冗余性及组合作用。本文构造了多个特征子集作为备选特征集,将从中选取最优特征子集作为模型输入特征。

1) 特征子集一:输电线路的有功功率、无功功率。

2) 特征子集二:输电线路的有功功率、无功功率以及母线电压幅值、相角。

3) 特征子集三:输电线路的有功功率、无功功率以及发电机有功、无功功率。

4) 特征子集四:输电线路的有功功率、无功功率、母线电压幅值、相角、发电机有功、无功功率以及负荷的有功、无功功率。

为了选取最优特征子集,本文对比不同输入特征下暂态稳定评估模型性能,选择 CNN 作为基础分类器,采用经典的 LeNet-5 结构,卷积核为 5,每层卷积层后连接步长为 1 的最大池化层。实验验证结果展示在表 2 中。

表 2 不同特征集下的模型评估性能
Table 2 Model evaluation performance under different feature sets

特征子集	Acc/%	Pre/%	Rec/%	F1/%
特征子集一	95.33	95.67	95.24	95.31
特征子集二	97.63	97.65	97.62	97.63
特征子集三	97.20	97.20	97.22	97.20
特征子集四	96.77	96.77	96.76	96.76

由表 2 可看出,模型以特征子集一(输电线路的有功功率、无功功率)为输入特征时,模型的准确率仅为 95.33;以特征子集二(输电线路的有功功率、无功功率以及母线电压幅值、相角);特征子集三(输电线路的有功功率、无功功率以及发电机有功、无功功率)作为输入特征时,模型准确率达到 97 以上,各项指标均表现良好;特征子集四(输电线路的有功功率、无功功率、母线电压幅值、相角、发电机有功、无功功率以及负荷的有功、无功功率)为输入特

征时,模型的状态辨识准确率出现一定的下降,仅为 96.77。这是由于特征子集四可能包含大量的低信息特征,影响模型性能。综上所述,选择以特征子集二作为本文模型的输入特征。

4.1.4 数据增强算法性能对比

为验证所提数据增强算法的有效性,本文设置稳定样本和失稳样本比例为 10:1 的一种场景,来模拟实际失稳样本稀少的情况,使用 WD 和 FID 指标评价 GAN 和 GAGN 算法性能,对比生成样本与实际样本的相似度,结果如表 3 所示。

表 3 不同数据增强算法性能对比
Table 3 Performance of enhancement algorithms

增强算法	WD	FID
GAN	6.47	2.52
GAGN	6.02	2.34

由表 3 可知,GAGN 的样本增强算法指标性能优于传统的 GAN 算法,其中 GAGN 的算法的 WD 指标比 GAN 的算法指标降低了 6.95%,GAGN 的算法的 FID 指标比 GAN 的算法 FID 指标降低了 7.14%,进一步说明 GAGN 扩增的不稳定样本的分布更接近真实的失稳样本分布。

4.1.5 离线训练算法性能对比

使用混淆矩阵评价暂态稳定时通常采用权重平均法计算指标,对每个类别的指标进行计算,并以每个类别的样本数量为权重进行加权平均。考虑到暂态稳定评估为非平衡二分类问题,当样本比例不均衡的情况下,这种计算方法极大程度上偏向数量多的指标,对数量少的类别性能评估不够全面。为应对不均衡情况导致指标评估不全面的问题,本文引入一种更具综合性的宏平均方法来计算指标,对每个类别的指标单独计算后,取算术平均值。本文设置了多种样本比例模拟实际电网的样本不均衡情况,表 4 为算法在不同样本比例上的测试效果。

由表 4 可知,在采用权重平均法评估指标时,评估指标过多地受到数量较多的样本类别的影响。尽管整体准确率较高,但这并不能准确反映模型对失稳样本的辨识性能。相比之下,宏平均法在整体性能评估中更公平地体现了不同类别的实际影响,避免了评估结果过度受到数量多的样本类别的影响。随着样本比例的极端化,未经增强的 CNN 模型性能指标显著下降,Pre、Rec 和 F1 指标降低至 50%以下,而经过增强后的 CNN 算法,在多种极端平衡的样本比例场景下均显示出良好的性能。基于 GAGN 的增强算法各指标均达 98%以上,证明所提方法可有效提高模型对失稳样本的辨识准确率。

表 4 不同样本比例下样本增强算法模型评估性能

Table 4 Evaluation performance of sample enhancement algorithm models under different sample proportions

模型	样本比例	宏平均方法				权重平均法			
		Acc/%	Pre/%	Rec/%	F1/%	Acc/%	Pre/%	Rec/%	F1/%
仅 CNN	10:1	97.77	98.16	88.39	92.60	97.77	97.78	97.77	97.64
	100:1	99.23	83.69	78.64	80.95	99.23	99.18	99.23	99.20
	1000:1	99.90	49.95	50.00	49.97	99.90	99.80	99.90	99.85
CNN+GAN	10:1	96.15	96.25	96.12	96.15	96.15	96.23	96.15	96.15
	100:1	99.60	99.60	99.60	99.60	99.60	99.60	99.60	99.60
	1000:1	99.95	99.95	99.95	99.95	99.95	99.95	99.95	99.95
CNN+GAGN	10:1	98.83	98.82	98.83	98.83	98.83	98.83	98.83	98.83
	100:1	99.68	99.68	99.68	99.68	99.68	99.68	99.68	99.68
	1000:1	99.98	99.98	99.98	99.98	99.98	99.98	99.98	99.98

为进一步细化分析增强算法对不平衡场景的提升作用，本文分别绘制了稳定样本和失稳样本在不同比例下的实验结果，如图 7 所示。图 7 中：下标_s 表示稳定样本辨识准确率结果，下标_us 表示失稳样本辨识准确率结果；红色为稳定样本的指标，绿色为失稳样本的指标。由图 7 可知，在多种样本比例不平衡的情况下，增强前模型中稳定样本的评

估指标均表现良好，而失稳样本的指标随着样本不平衡比例下降也呈现下降趋势。这是因为原数据集中失稳样本较少，模型无法充分学习失稳样本的分布特性；采用基于 GAGN 的数据增强算法后，通过补充失稳样本的特征空间，提高了深度学习模型对失稳样本的识别准确率，有效减少了失稳样本的漏判率。




图 7 不同样本比例下模型对各类别样本的评估性能

Fig. 7 Evaluation performance of the model on samples of different categories under different sample ratios

5 结论

针对电力系统样本不平衡和模型泛化性较差的问题，本文提出一种考虑样本分布不平衡的电力系统暂态稳定自适应评估框架，在 IEEE39 节点系统上进行验证，所得结论如下：

- 1) 与传统的生成对抗网络相比，基于 GAGN 数据增强算法生成的失稳数据质量更高，更接近真实的电网数据特性。
- 2) 基于增强后数据集训练的模型鲁棒性更强，提高了不平衡样本辨识的准确率，在多个不平衡样本比例下均表现出良好的性能。

3) 所提出的主动迁移学习策略挑选出的关键样本可有效降低模型更新成本,在多个目标系统下均表现良好,提升了模型在新运行场景下的泛化性。

附录见本刊网络版(<http://www.dwjs.com.cn/CN/1000-3673/current.shtml>)。

参考文献

- [1] 毛安家, 马静, 蒯圣宇, 等. 高比例新能源替代常规电源后系统暂态稳定与电压稳定的演化机理[J]. 中国电机工程学报, 2020, 40(9): 2745-2755.
MAO Anjia, MA Jing, KUAI Shengyu, et al. Evolution mechanism of transient and voltage stability for power system with high renewable penetration level[J]. Proceedings of the CSEE, 2020, 40(9): 2745-2755(in Chinese).
- [2] 杨银国, 袁泉添, 陆秋瑜, 等. 考虑切换动态的功率同步控制单台构网型换流器暂态稳定性分析[J]. 电网技术, 2023, 47(10): 4005-4016.
YANG Yinguo, YUAN Xiaotian, LU Qiuyu, et al. Transient stability analysis of grid-forming converter with power synchronization control considering switching dynamics[J]. Power System Technology, 2023, 47(10): 4005-4016(in Chinese).
- [3] 李亚楼, 张星, 胡善华, 等. 含高比例电力电子装备电力系统安全稳定分析建模仿真技术[J]. 电力系统自动化, 2022, 46(10): 33-42.
LI Yalou, ZHANG Xing, HU Shanhua, et al. Modeling and simulation technology for stability analysis of power system with high proportion of power electronics[J]. Automation of Electric Power Systems, 2022, 46(10): 33-42(in Chinese).
- [4] ZADKHAHAST P, JATSKEVICH J, VAAHEDI E. A multi-decomposition approach for accelerated time-domain simulation of transient stability problems[J]. IEEE Transactions on Power Systems, 2015, 30(5): 2301-2311.
- [5] 安军, 艾士琪, 刘道伟, 等. 基于短时受扰轨迹的电力系统暂态稳定评估方法[J]. 电网技术, 2019, 43(5): 1690-1697.
AN Jun, AI Shiqi, LIU Daowei, et al. A power system transient stability assessment method based on short-time disturbed trajectories [J]. Power System Technology, 2019, 43(5): 1690-1697(in Chinese).
- [6] 朱乔木, 陈金富, 李弘毅, 等. 基于堆叠自动编码器的电力系统暂态稳定评估[J]. 中国电机工程学报, 2018, 38(10): 2937-2946.
ZHU Qiaomu, CHEN Jinfu, LI Hongyi, et al. Transient stability assessment based on stacked autoencoder[J]. Proceedings of the CSEE, 2018, 38(10): 2937-2946(in Chinese).
- [7] 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): 7596-7607.
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): 7596-7607(in Chinese).
- [8] 赵琦, 王新迎, 乔骥. 数据驱动的能源互联网建模与仿真关键技术[J]. 电力信息与通信技术, 2020, 18(1): 39-45.
ZHAO Qi, WANG Xinying, QIAO Ji. Key technologies of data-driven energy interconnection modeling and simulation[J]. Electric Power Information and Communication Technology, 2020, 18(1): 39-45(in Chinese).
- [9] 黄济宇, 管霖, 郭梦轩, 等. 图深度学习技术在智能暂态稳定评估中的应用及展望[J]. 电网技术, 2023, 47(4): 1500-1511.
HUANG Jiyu, GUAN Lin, GUO Mengxuan, et al. Application and prospect of graph deep learning technique in intelligent transient stability assessment[J]. Power System Technology, 2023, 47(4): 1500-1511(in Chinese).
- [10] 李永康, 刘宝柱, 胡俊杰. 基于数据驱动与时域仿真融合的电力系统暂态稳定快速评估[J]. 电网技术, 2023, 47(11): 4386-4395.
LI Yongkang, LIU Baozhu, HU Junjie. Rapid evaluation of power system transient stability based on fusion of data-driven and time-domain simulation[J]. Power System Technology, 2023, 47(11): 4386-4395(in Chinese).
- [11] XU Yan, DONG Zhaoyang, ZHAO Junhua, et al. A reliable intelligent system for real-time dynamic security assessment of power systems[J]. IEEE Transactions on Power Systems, 2012, 27(3): 1253-1263.
- [12] WANG Bo, FANG Biwu, WANG Yajun, et al. Power system transient stability assessment based on big data and the core vector machine[J]. IEEE Transactions on Smart Grid, 2016, 7(5): 2561-2570.
- [13] 杨燕, 杨知方, 余娟, 等. 基于深度学习的含不确定性 $N-1$ 安全校核方法[J]. 中国电机工程学报, 2021, 41(8): 2716-2725.
YANG Yan, YANG Zhifang, YU Juan, et al. Fast analysis of $N-1$ contingency screening with uncertainty scenarios based on deep learning[J]. Proceedings of the CSEE, 2021, 41(8): 2716-2725(in Chinese).
- [14] LIU Songka, LIU Lihuang, FAN Youping, et al. An integrated scheme for online dynamic security assessment based on partial mutual information and iterated random forest[J]. IEEE Transactions on Smart Grid, 2020, 11(4): 3606-3619.
- [15] 陈佛计, 朱枫, 吴清潇, 等. 生成对抗网络及其在图像生成中的应用研究综述[J]. 计算机学报, 2021, 44(2): 347-369.
CHEN Fojie, ZHU Feng, WU Qingxiao, et al. A survey about image generation with generative adversarial nets[J]. Journal of Computer Science, 2021, 44(2): 347-369(in Chinese).
- [16] 张彬, 周粤川, 张敏, 等. 生成对抗网络改进角度与应用研究综述[J]. 计算机应用研究, 2023, 40(3): 649-658.
ZHANG Bin, ZHOU Yuechuan, ZHANG Min, et al. Review of research on improvement and application of generative adversarial networks[J]. Application Research of Computers, 2023, 40(3): 649-658(in Chinese).
- [17] 廖鑫, 唐志强, 曹纭. 基于生成对抗网络的空域彩色图像隐写失真函数设计方法[J]. 软件学报, 2022, 33(9): 3470-3484.
LIAO Xin, TANG Zhiqiang, CAO Yun. Steganographic distortion function design method for spatial color image based on GAN[J]. Journal of Software, 2022, 33(9): 3470-3484(in Chinese).
- [18] 杨东升, 吉明佳, 周博文, 等. 基于双生成器生成对抗网络的电力系统暂态稳定评估方法[J]. 电网技术, 2021, 45(8): 2934-2945.
YANG Dongsheng, JI Mingjia, ZHOU Bowen, et al. Transient stability assessment of power system based on DGL-GAN[J]. Power System Technology, 2021, 45(8): 2934-2945(in Chinese).
- [19] ZHAN Xianwen, HAN Song, RONG Na, et al. A hybrid transfer learning method for transient stability prediction considering sample imbalance[J]. Applied Energy, 2023, 333: 120573.
- [20] 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 evaluation of transient stability in power systems based on improved DCGAN[J]. Automation of Electric Power Systems, 2022, 46(2): 73-82(in Chinese).
- [21] 杨挺, 赵黎媛, 王成山. 人工智能在电力系统及综合能源系统中的应用综述[J]. 电力系统自动化, 2019, 43(1): 2-14.
YANG Ting, ZHAO Liyuan, WANG Chengshan. Review on application of artificial intelligence in power system and integrated energy system[J]. Automation of Electric Power Systems, 2019, 43(1):

- 2-14(in Chinese).
- [22] 葛铁洲, 刘恒, 王言, 等. 小样本困境下的深度学习图像识别综述[J]. 软件学报, 2022, 33(1): 193-210.
GE Yizhou, LIU Heng, WANG Yan, et al. Survey on deep learning image recognition in dilemma of small samples[J]. Journal of Software, 2022, 33(1): 193-210(in Chinese).
- [23] 赵晋泉, 夏雪, 徐春雷, 等. 新一代人工智能技术在电力系统调度运行中的应用评述[J]. 电力系统自动化, 2020, 44(24): 1-10.
ZHAO Jinquan, XIA Xue, XU Chunlei, et al. Review on application of new generation artificial intelligence technology in power system dispatching and operation[J]. Automation of Electric Power Systems, 2020, 44(24): 1-10(in Chinese).
- [24] 汤奕, 崔晗, 党杰. 基于继承思想的时变性电力系统暂态稳定预测[J]. 中国电机工程学报, 2021, 41(15): 5107-5118.
TANG Yi, CUI Han, DANG Jie. Transient stability prediction of time-varying power systems based on inheritance[J]. Proceedings of the CSEE, 2021, 41(15): 5107-5118(in Chinese).
- [25] XIE Jian, SUN Wei. A transfer and deep learning-based method for online frequency stability assessment and control[J]. IEEE Access, 2021, 9: 75712-75721.
- [26] 张若愚, 吴俊勇, 李宝琴, 等. 基于迁移学习的电力系统暂态稳定自适应预测[J]. 电网技术, 2020, 44(6): 2196-2203.
ZHANG Ruoyu, WU Junyong, LI Baoqin, et al. Self-adaptive power system transient stability prediction based on transfer learning[J]. Power System Technology, 2020, 44(6): 2196-2203(in Chinese).
- [27] 张宸滔, 郑永康, 卢继平, 等. 基于图神经网络的智能变电站二次回路故障定位研究[J]. 电力系统保护与控制, 2022, 50(11): 81-90.
ZHANG Chentao, ZHENG Yongkang, LU Jiping, et al. Fault location of secondary circuits in a smart substation based on a graph neural network[J]. Power System Protection and Control, 2022, 50(11): 81-90.
- [28] 张翼, 朱永利. 结合知识蒸馏和图神经网络的局部放电增量识别方法[J]. 电工技术学报, 2023, 38(5): 1390-1400.
ZHANG Yi, ZHU Yongli. Incremental partial discharge recognition method combining knowledge distillation with graph neural network [J]. Transactions of China Electrotechnical Society, 2023, 38(5): 1390-1400(in Chinese).
- [29] 丁嘉, 朱永利. 图学习与零序分量相结合的风电场集电线单相接地故障定位[J]. 电工技术学报, 2023, 38(17): 4701-4714.
DING Jia, ZHU Yongli. A fault localization scheme for single-phase-to-ground faults on collecting lines in wind farms combining graph learning and zero-sequence components[J]. Journal of Electrical Engineering Technology, 2023, 38(17): 4701-4714(in Chinese).
- [30] 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(in Chinese).
- [31] 谢培元, 袁文, 刘永刚, 等. 基于主动学习的电力系统暂态稳定评估方法[J]. 电测与仪表, 2021, 58(5): 86-91.
XIE Peiyuan, YUAN Wen, LIU Yonggang, et al. Transient stability assessment method in power system based on active learning[J]. Electrical Measurement & Instrumentation, 2021, 58(5): 86-91(in Chinese).
- [32] 王铮澄, 周艳真, 郭庆来, 等. 面向变化场景的输电断面极限评估主动迁移学习方法[J]. 中国电机工程学报, 2023, 43(15): 5732-5745.
WANG Zhengcheng, ZHOU Yanzhen, GUO Qinglai, et al. Active transfer learning for TTC assessment of transmission interfaces with changing operating scenarios[J]. Proceedings of the CSEE, 2023, 43(15): 5732-5745(in Chinese).



姬凯旋

在线出版日期: 2025-03-31。

收稿日期: 2024-05-11。

作者简介:

姬凯旋(1993), 女, 博士, 研究方向为电力人工智能、电力系统运行分析, E-mail: jikaixuan@epri.sgcc.com.cn;

乔骥(1991), 男, 高级工程师, 博士, 通信作者, 研究方向为电力调度运行优化, E-mail: qiaoji@epri.sgcc.com.cn;

赵紫璇(1995), 女, 硕士, 研究方向为电力人工智能, E-mail: zhaozixuan@epri.sgcc;

赵津蔓(1994), 女, 博士研究生, 研究方向为电力系统运行分析, E-mail: qiaoji@epri.sgcc.com.cn;

史梦洁(1989), 女, 高级工程师, 硕士, 研究方向为电力人工智能, E-mail: shimengjie@epri.sgcc.com.cn;

杨帆(1995), 女, 博士, 研究方向为电力可信智能增强技术, E-mail: yangfan@epri.sgcc.com.cn。

(责任编辑 徐梅)

附录 A

主动迁移学习方案效果对比

为验证算法实用性，本文在 4.1.1 节的初始设置基础上增加了新的场景：设置不同新能源出力下的运行方式，对部分线路进行“ $N-2$ ”校验，故障条件的设置和 4.1.1 节类似，通过时域仿真法生成新的运行方式、拓扑结构模拟电力系统新工况，仿真设置如表 A1 所示。

表 A1 目标系统场景设置
Table A1 Target System Scene Settings

	拓扑	运行方式
源系统	无变化	新能源大发
目标系统 1	无变化	新能源小发
目标系统 2	断开两条线路	新能源大发
目标系统 3	断开两条线路	新能源小发

当系统的运行方式或拓扑结构发生较大变化时，对比采用主动微调和仅微调的两种迁移策略后模型的性能。其中，仅微调方法为固定 CNN 网络前 4 层参数，利用全部目标域数据微调最后一层神经网络的参数。而主动微调学习方法是通过熵不确定方法挑选目标域数据，利用挑选后的高质量的目标域样本来微调最后一层参数。采用主动微调学习的策略可以在少量训练样本情况下依然可以使得模型达到较好的性能。

以目标系统 1 为例，分类模型为 4.1 中的 CNN 模型，如图 A1 所示。

当更新样本仅有 100 个时，模型学习的样本表达能力不足，进而影响了评估精度。随着样本数量的增加，模型的准确率逐步提升。本文进一步对比了微调与主动微调学习，可以发现在同样样本数量条件下，主动微调学习的准确率更高。例如，当更新样本数为 100 时，主动微调学习模型的准确率可以达到 98%，这表明主动学习能够有效挑选出包含关键信息的样本，从而提升模型的表现。




图 A1 目标系统 1 不同主动迁移学习策略对比

Fig. A1 Comparison of Different Active Transfer Learning Strategies for Target System 1

为进一步验证主动迁移策略的有效性，我们测试了该模型在多个不同目标域数据集上的表现，结果如表 A2 所示，可以看出，本文提出的主动微调学习方法更新后的模型性能显著优于传统的随机样本微调方法更新模型，通过主动选择具有代表性和信息丰富的样本进行模型更新，能够以低更新成本提升模型性能，有助于提升模型的鲁棒性和泛化性。

表 A2 不同目标系统下迁移性能对比
Table A2 Comparison of Migration Performance under Different Target Systems

	方法	Acc(%)	训练样本
场景 1	主动微调学习	98.05	200
	随机样本微调	88.48	
场景 2	主动微调学习	97.68	200
	随机样本微调	87.95	
场景 3	主动微调学习	97.84	500
	随机样本微调	89.68	

附录 B

暂态稳定预测结果的可解释性分析

在稳定预测结果的可解释性分析方面，本文从全局角度分析特征的重要性。使用 ELI5(Explain Like I'm Five)方法，计算每个特征对模型整体预测性能的影响。具体来说，通过多次打乱每个特征，并观察模型性能的变化，定量评估特征的全局重要性。结果如图 B1 所示。




图 B1 基于 ELI5 的特征重要性

Fig. B1 Feature importance based on ELI5

图中，横坐标表示特征的重要性权重，数值越大表示该特征对模型预测的影响越大。纵坐标为特征名称，由图可知，线路功率对暂态稳定的影响较大，排名前十的重要特征均为线路功率。同时，利用 SHAP(Shapley Additive Explanations)值进行特征重要性分析，计算每个特征的平均 SHAP 值，展示特征在整体模型中的贡献。生成特征重要性的图

表，展示全局视角下的特征影响。如图 B2 所示。图中横轴表示特征的 SHAP 值，SHAP 值越大，表示该特征对模型输出的影响越大，纵坐标为特征名称，从特征全局贡献看，线路有功、无功功率等特征对预测目标最高的影响力。




图 B2 基于 SHAP 的特征贡献度

Fig. B2 Characteristic contribution degree based on SHAP

另一方面，从局部角度对实例样本的预测结果做归因解释，利用 LIME(Local Interpretable Model-agnostic Explanations)工具，定量得到各变量对预测结果的正负性贡献权重。通过生成局部线性模型，可以直观地展示在不同特征作用下模型输出的变化。从图 B3 观察可见，线路 5、6、7、10、11 功率为重要特征，其他特征的重要性相对较低，实验结果与 ELI5、SHAP 全局分析结果一致，进一步验证了模型预测的可解释性。




图 B3 基于 LIME 的预测归因占比

Fig. B3 LIME based forecast attribution ratio

表 C1 不同样本比例下样本增强算法模型评估性能

Table C1 Performance evaluation of the sample enhancement algorithm model under various sample proportions

		宏平均方法				权重平均法			
	样本比例	Acc/%	Pre/%	Rec/%	F1/%	Acc/%	Pre/%	Rec/%	F1/%
增强前	10:1	96.97	93.65	85.89	89.31	96.97	96.84	96.97	96.92
	100:1	99.00	99.50	54.55	58.08	99.00	99.01	99.00	98.59
增强后	10:1	99.46	99.47	99.46	99.46	99.46	99.47	99.46	99.46
	100:1	99.58	99.58	99.58	99.58	99.58	99.58	99.58	99.58

附录 C

省级电网验证结果

本文以某省级电网 500kv 及其以上电压等级数据作为算例，某省级电网接线图如图 C1 所示。




图 C1 省级电网接线图

Fig. C1 Provincial grid wiring diagram

设置风电机组和光伏机组出力为 0-80%并以 20%为步长增长的潮流，相应改变火电机组出力使系统功率平衡且母线电压维持在 0.95~1.05p.u. 范围内，在此基础上对关键线路进行故障校验。故障持续时间分别为 0.10s。本文设置了多种样本比例模拟实际电网的样本不均衡情况，表 C1 为算法在不同样本比例下的测试结果。

由表可知，随着样本比例的极端化，未经增强的 CNN 模型的性能指标显著下降，Rec 和 F1 指标降低至 60%以下，而经过增强后的 CNN 算法，在多种极端平衡的样本比例场景下均显示出良好的性能，进一步证明所提方法的有效性。