

基于改进 McDalNet 的电力系统暂态电压稳定自适应评估方法

黄莹¹, 马彬喻², 吴亚骏¹, 潘晓杰¹, 邵德军¹, 石梦璇¹, 张慕婕¹

(1. 国家电网有限公司华中分部, 武汉 430077;
2. 武汉大学 电气与自动化学院, 武汉 430072)

摘要: 针对电力系统运行场景频繁切换导致的暂态电压稳定评估模型泛化性下降问题, 提出了一种基于改进 McDalNet(多分类域对抗学习网络)的电力系统暂态电压稳定自适应评估方法。首先, 采用 Wasserstein 距离构造 McDalNet 的损失函数, 以更好地捕捉场景切换前后的域分布差异, 并通过中心损失强化类内特征聚类, 从而更好地区分不同类样本。然后, 利用稳态、故障发生、故障清除 3 个采样时刻的特征训练特征提取器及标签分类器, 构建适用于原始场景的高精度评估模型。最后, 通过辅助分类器及少量目标域样本实现域对齐, 从而自适应更新模型, 使其适用于新场景的暂态电压稳定评估。算例分析表明, 所提方法能够对齐源域与目标域的数据分布, 有效提升电力系统运行场景多次切换后暂态电压稳定评估模型的泛化性和可持续学习能力。

关键词: 场景变化; 多分类域对抗学习网络; 暂态电压稳定; 电力系统

DOI: 10.19585/j.zjdl.202603002

开放科学(资源服务)标识码(OSID):



An adaptive transient voltage stability assessment method for power systems based on a modified McDalNet

HUANG Ying¹, MA Binyu², WU Yajun¹, PAN Xiaojie¹, SHAO Dejun¹, SHI Mengxuan¹, ZHANG Mujie¹

(1. Central China Branch of State Grid Corporation of China, Wuhan 430077, China;

2. School of Electrical Engineering and Automation, Wuhan University, Wuhan 430072, China)

Abstract: To address the degradation in model generalization caused by frequent switching of power system operating scenarios in transient voltage stability assessment (TVSA) models, an adaptive assessment method based on a modified multi-class domain adversarial learning networks (McDalNet) is proposed. First, the modified McDalNet uses the Wasserstein distance to construct the loss function to more effectively capture domain distribution discrepancies before and after scenario switching, while a center loss is introduced to enhance intra-class feature clustering, thereby improving the separability of samples from different classes. Subsequently, the feature extractor and label classifier are trained using features from three sampling moments; steady-state, fault occurrence, and fault clearance, to build a high-precision assessment model for the original scenario. Finally, domain alignment is achieved through an auxiliary classifier and a small number of target-domain samples, enabling adaptive model updating so that it can be applied to TVSA in new scenarios. Case studies demonstrate that the proposed method can align the data distributions of the source and target domains, effectively enhancing the generalization performance and continual learning capability of TVSA models under multiple operating scenario transitions in power systems.

Keywords: scenario variation; McDalNet; transient voltage stability; power system

0 引言

随着大规模新能源机组和新型负荷的并网运行以及电网的广泛互联, 电力系统的运行方式和

拓扑结构频繁变化, 其安全稳定运行面临更大的风险, 暂态电压稳定动态特性更加复杂^[1-3], 因此, 需要开展暂态电压稳定评估, 以防止电网发生暂态电压失稳、电压崩溃等严重故障。

传统的暂态稳定分析方法, 如时域仿真法^[4]和暂态能量函数法^[5]在面对规模和复杂度不断扩大的电力系统时, 已难以满足在线评估所需的快

速性和准确性。然而,随着人工智能技术的发展以及广域测量系统中PMU(同步相量测量单元)的大量安装,基于数据驱动的方法已广泛应用于电力系统暂态电压稳定评估^[6],可利用大量历史数据训练评估模型,构建系统故障后特征与系统稳定状态之间的映射关系,进而快速获得高精度预测结果。数据驱动方法主要包含浅层学习和深度学习。浅层学习模型包括支持向量机^[7]、贝叶斯神经网络^[8]、决策树及随机森林算法^[9-10]等。这类模型结构简单,训练和评估速度快,但在大规模电网下,其评估精度往往难以提升。深度学习模型包括卷积神经网络^[11]、长短时记忆网络^[12]、堆叠自动编码器^[13]、深度置信网络^[14]和图神经网络^[15]等,这些模型凭借其更强大的非线性拟合能力,显著提升了暂态电压稳定评估的精度。

然而,上述评估方法的高精度均以采用预期故障构造的训练数据集与实际应用中的数据遵循相同分布为前提。但实际电力系统的运行场景、拓扑结构等经常发生频繁切换,这将导致不同场景特征表征产生偏差,从而大大降低模型的评估性能和准确性^[16]。为提高暂态电压稳定评估模型的通用性,近年来引入了迁移学习方法用于暂态电压稳定评估,通过将代表原始场景的源域信息迁移至代表新场景的目标域当中,实现自适应的暂态电压稳定评估,主要分为样本迁移、特征迁移及模型迁移。文献^[17]提出了一种样本迁移方法,通过继承源域样本中类似于目标域样本的部分来实现迁移,其利用了源域样本中的知识,但忽略了目标域样本和现有模型中提供的信息,存在局限性。文献^[18]基于源域训练数据和目标域数据的相似性,通过重新加权训练数据的某些部分实现样本迁移,但权重较低的数据可能导致样本重要信息丢失。文献^[19]采用MMD(最大均值差异)指标衡量不同数据的边际和条件分布之间的差异,使模型适应多种未知故障,但其考虑的特征信息较少,并不适用于多变量时间序列的模型输入数据。文献^[20]提出了一种模型迁移方法,使用在ImageNet上预训练的深度卷积神经网络,冻结部分卷积层,并通过微调共享参数来提高训练模型的泛化能力,但部分共享参数的调整易使模型遗忘已学知识,迁移的改善效果有限,可持

续学习能力较低。文献^[21]采用域对抗网络提取不同域间的公共特征以实现模型更新,但域分类器在区分源域与目标域时存在困难,模型迁移后的评估精度有待提高,且没有考虑电力系统运行场景的连续多次切换情况。综上所述,基于迁移学习的暂态电压稳定评估仍存在样本与模型知识利用不充分、时序特征兼容性不足、域分布衡量不精准、类内区分不足以及在运行场景频繁切换下可持续学习能力不佳等问题^[22-25]。

针对以上不足,本文提出了一种基于改进McDalNet(多分类域对抗学习网络)的电力系统暂态电压稳定自适应评估方法,以实现电力系统运行场景切换后的自适应暂态电压稳定评估。通过改进McDalNet的损失函数,利用Wasserstein距离构造MCS D(多类评分分歧)的替代函数,能更敏感地捕捉电力系统不同场景切换后的特征空间偏移。同时,引入中心损失函数,强化同一稳定类别样本的特征聚类,从而提升模型区分不同类别样本的性能。所提模型以故障前的稳态时刻、故障发生时刻、故障清除时刻的3个采样关键时间点的时序特征量为输入,在电力系统运行场景切换后,利用少量目标域样本实现不同域分布的对齐,使样本在特征空间中满足域不变性,从而自适应更新模型,提高暂态电压稳定评估模型在运行场景连续频繁切换下的泛化性和可持续学习能力。通过在改进的IEEE 39节点系统和美国南卡罗莱纳州500节点电网仿真上验证了该方法的有效性。

1 McDalNet模型

McDalNet是一种域自适应类型的迁移学习算法^[26],其基本结构如图1所示。域自适应的核心在于衡量不同域间的差异,并通过训练缩小这些差异,以提升模型的泛化性能。McDalNet通过构建MCS D散度来衡量域分布之间的距离。

MCS D相对于某一域上的分布 D 定义为:

$$\text{MCS D}_D(f', f'') = \frac{1}{K} E_{x \sim D} \| M(f'(x)) - M(f''(x)) \|_1 \quad (1)$$

式中: f' 和 f'' 为一对评分函数; x 为同一域中的样本; K 为 x 的类别数; E 为期望; $\|\cdot\|_1$ 为L1范数; M 为绝对边界的相关矩阵。

M 的定义如下:

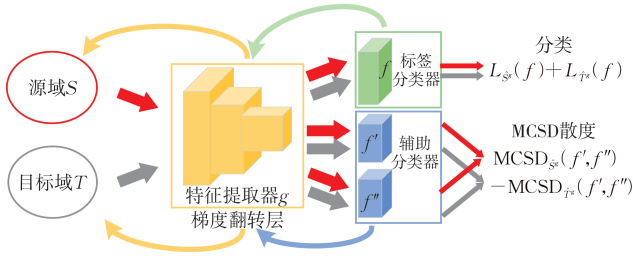


图 1 多分类域对抗学习网络基本结构

Fig.1 Basic structure of the McDalNet

$$M_{i,j}(f(x)) = \Phi_\rho(\mu_i(f(x), j)) \quad (2)$$

式中: $\Phi_\rho(\cdot)$ 为坡道损失函数; $\mu_i(f(x), j)$ 为绝对边界函数。二者的定义如式(3)、(4)所示。

$$\Phi_\rho(x) = \begin{cases} 0, & \rho \leq x \\ 1 - x/\rho, & 0 < x < \rho \\ 1, & x \leq 0 \end{cases} \quad (3)$$

$$\mu_k(f(x), y) = \begin{cases} +f_k(x), & k = y \\ -f_k(x), & k \in \mathcal{Y} \setminus \{y\} \end{cases} \quad (4)$$

式中: ρ 为坡道损失系数; y 为样本类别标签; \mathcal{Y} 为样本类别集合; $f_k(x)$ 满足和为 0 的约束, 即 $\sum_{k=1}^K f_k(x) = 0$ 。

定义源域与目标域分布间的 MCDSD 散度为:

$$d_{\text{MCDSD}}(S_x, T_x) = \sup_{f', f'' \in F} [\text{MCDSD}_{T_x}(f', f'') - \text{MCDSD}_{S_x}(f', f'')] \quad (5)$$

式中: S_x 为源域样本分布; T_x 为目标域样本分布; F 为评分函数空间。

如图 1 所示, McDalNet 由特征提取器 g 、标签分类器 f 及辅助分类器 f' 和 f'' 构成。辅助分类器的作用是最大化源域与目标域分布之间的 MCDSD 散度, 从而区分不同域间的样本。而特征提取器及标签分类器旨在最小化标签分类器分类损失及 MCDSD 散度, 以提升模型对不同域样本的泛化性。通过采用梯度反转层来实现这两种目标之间的对抗训练, 网络优化目标为:

$$\min_{f, g} L_{\hat{S}_x}(f) + L_{\hat{T}_x}(f) + [\text{MCDSD}_{\hat{T}_x}(f', f'') - \text{MCDSD}_{\hat{S}_x}(f', f'')] \quad (6)$$

$$\max_{f', f''} [\text{MCDSD}_{\hat{T}_x}(f', f'') - \text{MCDSD}_{\hat{S}_x}(f', f'')] \quad (7)$$

式中: \hat{S}_x 和 \hat{T}_x 分别为特征提取器上源域与目标域的经验分布; $L(\cdot)$ 为分类损失。

采用坡道损失容易导致梯度消失, 本文采用

标准对数损失作为分类损失, 引入交叉熵损失构造 MCDSD 的替代函数。该函数能够表征评分函数 f' 和 f'' 中的 MCDSD, 修正后的网络优化目标表示为:

$$\min_{f, g} \{ E_{x \sim \hat{S}} - \log [\phi(f(g(x)))] \} + \{ E_{x \sim \hat{T}} - \log [\phi(f(g(x)))] \} + \quad (8)$$

$$[\text{MCDSD}'_{\hat{T}_x}(f', f'') - \text{MCDSD}'_{\hat{S}_x}(f', f'')] \quad (9)$$

式中: $\phi(\cdot)$ 为 softmax 函数; $\text{MCDSD}'(f', f'')$ 为 MCDSD 的替代函数。

$\text{MCDSD}'_D(f', f'')$ 在分布 D 中定义为:

$$\text{MCDSD}'_D(f', f'') = E_{x \sim D} \frac{1}{2} [CE(\phi(f'(g(x))), \phi(f''(g(x)))) + CE(\phi(f''(g(x))), \phi(f'(g(x))))] \quad (10)$$

式中: $CE(\cdot, \cdot)$ 为交叉熵损失函数。

McDalNet 所提供的对抗学习策略, 能够促进特征提取器网络 g 学习到邻域不变的条件特征分布, 从而提升模型对不同域样本的分类性能, 适用于解决因电力系统运行场景变化而导致的数据分布差异问题, 进而有效应对暂态电压稳定评估中的挑战。

2 基于改进 McDalNet 的暂态电压稳定自适应评估模型

2.1 改进 McDalNet

针对电力系统暂态电压稳定评估中运行场景频繁切换导致的域分布细微偏移问题, 传统的 McDalNet 采用交叉熵损失构造 MCDSD 的替代函数。然而, 在场景切换后, 电网的运行状态发生改变, 其运行数据在特征空间中的分布与原场景存在位置偏移。交叉熵损失对分布的细微差异不敏感, 且易因梯度饱和导致训练停滞, 难以捕捉电力系统场景切换引发的特征空间渐进偏移。相比之下, 使用 Wasserstein 距离能够精准捕捉电力系统场景切换后的特征空间细微偏移, 更有效地指导模型学习域不变特征, 帮助模型对齐两个域的分布。同时, Wasserstein 距离在优化过程中能够提供更稳定的梯度, 避免因梯度消失导致的训练停滞, 使得模型训练更加稳定。然而, Wasser-

stein距离需显式求解联合分布 γ , 计算复杂度较高。为解决这一问题, 文献[27]提出了SWD(切片 Wasserstein 距离)作为其变分近似形式, 通过随机投影将高维分布映射至一维子空间。SWD 不仅降低了计算成本, 还保留了分布差异度量的几何意义, 其定义如下:

$$SW(S, T) = E_{\theta \sim S^{d-1}} [W_2(S_\theta, T_\theta)] \quad (11)$$

式中: S^{d-1} 为 d 维单位球面; θ 为从 S^{d-1} 中均匀采样的投影方向; S_θ 和 T_θ 分别为分布 S 和分布 T 沿投影方向 θ 的一维线性投影操作; $W_2(\cdot, \cdot)$ 为一维分布间的2阶 Wasserstein 距离的平方, 即 $W_2(S_\theta, T_\theta) = \frac{1}{N} \sum_{i=1}^N \|p_i - q_i\|^2$; N 为样本数量; p_i 和 q_i 分别为分布 S 和分布 T 在投影方向 θ 上按数值排序后的第 i 个样本。

离散样本的SWD为:

$$W'(S, T) = \frac{1}{M} \sum_{m=1}^M \frac{1}{N} \sum_{n=1}^N \|p_i^{\theta_m} - q_i^{\theta_m}\|^2 \quad (12)$$

式中: M 为随机投影方向的数量, 设为128; θ_m 为第 m 个随机采样的投影方向; $p_i^{\theta_m}$ 和 $q_i^{\theta_m}$ 分别为分布 S 和分布 T 经方向 θ_m 投影后按数值排序的第 i 个样本值。

采用SWD构造MCSD替代函数的表达式如下:

$$\begin{aligned} \text{MCSD}_D^w(f', f'') = & E_{x \sim D} \frac{1}{2} [W'(\phi(f'(g(x))), \phi(f''(g(x)))) + \\ & W'(\phi(f''(g(x))), \phi(f'(g(x))))] \end{aligned} \quad (13)$$

式中: $W'(\cdot, \cdot)$ 为SWD的计算式。

中心损失能够使同一类别的样本特征在特征空间中更紧密地聚集在各自类别的中心附近。对于暂态电压稳定评估, 引入中心损失能够使同一域中同一类样本(例如暂态电压失稳样本)的特征映射到更相近的位置, 同时增大与暂态电压稳定样本特征的距离, 从而提高模型对各类别的分类准确性。中心损失函数表达式如下:

$$L_c = \frac{1}{N} \sum_{i=1}^N \|x_i - C_{y_i}\|_2^2 \quad (14)$$

式中: N 为样本数量; x_i 为第 i 个样本的特征量; C_{y_i} 为类别 y_i 的类别中心。

改进后的McDalNet总体损失函数表达式为:

$$\begin{aligned} \min_{f, g} [& E_{x \sim S} - \log [\phi(f(g(x)))] + \\ & [E_{x \sim T} - \log [\phi(f(g(x)))] + \\ & [\text{MCSD}_{T^*}^w(f', f'') - \text{MCSD}_{S^*}^w(f', f'')] + \\ & \lambda \cdot L_c^S + \lambda \cdot L_c^T \end{aligned} \quad (15)$$

式中: L_c^S 和 L_c^T 分别为源域和目标域的中心损失; λ 为中心损失的系数。

本文对McDalNet进行了改进, 构建了域间对齐与类内聚类的优化机制, 实现了域间差异最小化与类内一致性最大化的优化目标。改进后的模型不仅能够学习域不变特征以减小域之间的差异, 还注重在每个域内对各类别的样本进行有效聚类, 从而更好地区分不同类别的样本, 进而提升模型学习的泛化性能。

2.2 模型输入及评价指标

电力系统的暂态电压稳定性表征了系统在大扰动下的动态特性, 因此评估模型的输入特征量选取对评估效果尤为关键。利用电力系统中大量安装的PMU(同步相量测量单元)能够实时获取系统中的各电气量特征。在时间轴上, 这些特征可以分为系统故障前的稳态运行数据、故障发生期间的数据以及故障切除后系统恢复过程的数据^[21]。为了使模型输入特征尽可能反映系统的动态特性, 同时降低时序数据的冗余性, 本文选取故障发生前的稳态时刻、故障发生瞬间时刻及故障切除瞬间时刻这3个关键时间点的特征作为模型输入。具体特征包括各发电机有功 P_G 和无功功率 Q_G 、各负荷有功 P_L 和无功功率 Q_L 、各母线电压的幅值 U 和相角 θ 、各线路的传输有功功率 P_B 和无功功率 Q_B 。对输入特征进行归一化处理, 将特征值范围调整至 $[-1, 1]$, 以消除各特征量纲之间的差异, 从而提高模型的训练效果和评估精度。

本文采用的暂态电压稳定判据为: 系统在发生故障后的10s内, 若负荷母线电压恢复到0.8 p.u.以上, 则判定为暂态电压稳定; 否则判定为暂态电压失稳^[28-29]。基于这一判据, 对所有样本的稳定状态进行标注, 其中稳定样本标注为“0”, 失稳样本标注为“1”, 以便于分类模型的训练。由于模型对样本的暂态电压稳定预测属于二分类问题, 故可采用混淆矩阵来刻画模型的准确性能, 如表1所示。

表1中, N_{TS} 为稳定样本被正确分类的数目,

表1 混淆矩阵

Table 1 Confusion matrix

混淆矩阵	实际稳定	实际失稳
预测稳定	N_{TS}	N_{FS}
预测失稳	N_{FU}	N_{TU}

N_{FS} 为稳定样本被错误分类的数目, N_{TU} 为失稳样本被正确分类的数目, N_{FU} 为失稳样本被错误分类的数目。基于上述定义, 构建模型的准确性指标 λ_A 和模型的稳定性指标 λ_G 作为暂态电压稳定评估模型效果的评价指标^[30]:

$$\lambda_A = \frac{N_{TS} + N_{TU}}{N_{TS} + N_{FU} + N_{TU} + N_{FS}} \times 100\% \quad (16)$$

$$\lambda_G = \sqrt{\frac{N_{TS} \cdot N_{TU}}{(N_{TS} + N_{FU}) \cdot (N_{TU} + N_{FS})}} \times 100\% \quad (17)$$

式中: λ_A 为暂态电压稳定评估的总体准确率; λ_G 为稳定样本识别率和失稳样本识别率的几何平均值, 用来衡量模型的整体稳定性, λ_G 越高, 则稳定和失稳样本被正确分类的比例越高。

2.3 暂态电压稳定自适应评估流程

本文以电力系统量测数据作为模型输入, 构建了基于改进McDalNet的暂态电压稳定自适应评估流程, 如图2所示。该流程主要包括原始运行场景的源域离线训练、切换运行场景的目标域迁移学习模型更新、在线评估三方面。具体流程如下:

1)原始运行场景的源域离线训练: 根据历史运行数据和时域仿真数据构建原始运行场景的样本数据集, 数据集由2.2节所述的模型输入特征构成; 对数据进行归一化处理, 并根据样本的暂态电压稳定情况对样本进行标注, 标注后的样本称为源域样本, 并分为源域训练集和源域测试集; 利用源域训练集仅训练基于改进McDalNet的暂态电压稳定自适应评估模型中特征提取器 g 和标签分类器 f , 辅助分类器 f' 和 f'' 暂时不参与训练, 从而得到适用于原始运行场景的高精度暂态电压稳定评估模型。

2)切换运行场景的目标域迁移学习模型更新: 当电网的运行场景发生切换时, 将少量带标签的目标域数据作为目标域训练集, 与等量的源域训练集数据共同作为模型输入训练数据; 在训练过程中, 模型利用辅助分类器 f' 和 f'' 产生的MCSD

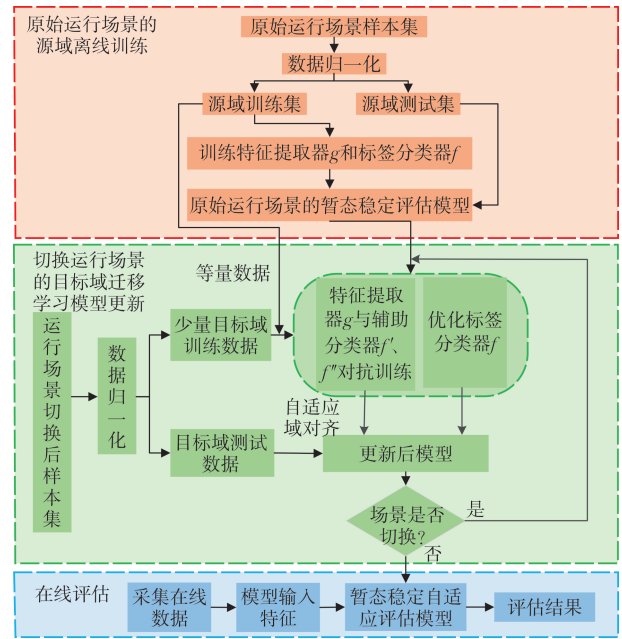


图2 暂态电压稳定自适应评估流程

Fig.2 Adaptive assessment process of transient voltage stability

散度以及梯度反转层进行特征提取器 g 和辅助分类器 f' 、 f'' 的对抗训练, 使模型特征提取器 g 提取的源域特征空间 \hat{S}^s 与目标域特征空间 \hat{T}^s 自适应的域对齐; 同时, 标签分类器 f 通过优化分类损失, 提高模型对目标域样本的适应性, 二者共同实现模型的自适应更新; 若电网运行场景再次发生切换, 重复步骤2, 实现评估模型的持续自适应更新。

3)在线评估: 在电力系统运行过程中, 采集在线数据, 获取模型输入所需的相应特征, 并将其输入训练好的评估模型中, 快速得到在线评估预测结果。

3 仿真与结果分析

为验证基于改进McDalNet的电力系统暂态电压稳定自适应评估方法的有效性, 采用Python编程语言和深度学习框架Pytorch搭建了改进的McDalNet模型。仿真实验所用计算机配置为: 13th Gen Intel® Core(TM) i5-13400F CPU、16.0 GB RAM。

3.1 数据集生成

IEEE 39节点系统包含10台同步发电机、19个负荷和34条交流线路。为考虑可再生能源机组接入对系统暂态电压稳定的影响, 本文采用改进

的IEEE 39节点系统作为测试算例。在改进的IEEE 39节点系统中,连接到母线33、34和36的同步发电机被风力发电机组等容量替换,连接到母线35、37的同步发电机被太阳能发电机组等容量替换,替换后,新能源的装机容量占系统总量的52.2%。改进的IEEE 39节点系统拓扑结构如图3所示。




图3 改进的IEEE 39节点系统

Fig.3 Modified IEEE 39-bus system

采用机电暂态仿真软件PSS/E搭建该系统并进行时域仿真,系统中所有负荷均采用ZIP综合负荷模型。为使离线仿真能够覆盖不同运行水平的系统状态,设置8种不同负荷水平,分别为额定负荷的80%、85%、90%、95%、100%、105%、110%和115%。风力发电机组的出力在其额定容量的30%~100%之间随机波动,太阳能发电机组的出力在其额定容量的0%~100%之间随机波动。负荷和新能源出力的变化由系统中各同步发电机按额定容量比例分担。故障位置均设置在交流线路上,具体位置为位于每条线路总长的2%、20%、40%、60%、80%及98%处,故障类型为三相接地短路。故障发生时间为仿真开始后的5s,故障持续时间分别为0.10s、0.15s、0.20s、0.25s和0.3s,仿真总时长设为20s。通过上述设置,共获得7869个有效样本。这些样本作为代表原始运行场景的源域样本,并按照7:3的比例随机划分为源域训练集和源域测试集。

考虑到电力系统运行场景的频繁变化,本文设置了3种运行场景连续切换的目标域样本,分别为T1场景、T2场景和T3场景,具体如下:

1) T1场景:在80%、85%、90%、95%、100%、105%、110%和115%的标准负荷水平下,切除2个负荷L20和L25,同时2台发电机G34和G37因检修暂时脱网,线路B7—B8及线路B16—B24因检修暂时断开。

2) T2场景:在T1场景的基础上,线路B7—B8及线路B16—B24检修完成重新并网。

3) T3场景:在T2场景的基础上,线路B5—B6与另一线路同时发生三相短路故障,线路B5—B6的故障位置在其总长的50%处,另一线路的故障位置分别在其支路总长的2%、20%、40%、60%、80%和98%处。

从每个目标域场景的仿真结果中,均随机选择6000个样本作为对应目标域的测试数据。

3.2 迁移学习效果测试

改进McDalNet的模型结构参数如表2所示。首先,利用源域训练集输入所提模型,仅对模型的特征提取器 g 和标签分类器 f 进行训练。源域训练样本的训练迭代次数设为200,训练批大小设为128。网络优化器采用SGD(随机梯度下降),并构造随迭代次数指数衰减的学习率,以促进模型在训练前期更快地学习以及在训练后期更好地收敛。学习率的表达式如下:

$$l_t = \frac{l_0}{(1 + \beta k)^\gamma} \quad (18)$$

式中: l_0 为初始学习率,设为0.01; k 为当前迭代数与总迭代数的比值;参数 β 设为10; γ 设为0.75。

为评估特征选择对模型性能的影响,对比了不同特征组合训练的模型在源域测试样本上的评

表2 改进McDalNet的结构参数

Table 2 Structural parameters of the modified McDalNet

网络层数	特征提取器 g	标签分类器 f	辅助分类器 f'	辅助分类器 f''
1	卷积层(64, 3), 批规范化层, ReLU层	全连接层(2)	全连接层(2)	全连接层(2)
2	卷积层(128, 3), 批规范化层, ReLU层	—	—	—
3	卷积层(128, 3), 批规范化层, ReLU层	—	—	—
4	卷积层(256, 3), 批规范化层, ReLU层	—	—	—
5	自适应平均池化层(1)	—	—	—

估性能。选取的特征组合方案包括:方案1为本文所提特征集;方案2为仅故障清除时刻的全部特征;方案3为含故障发生及故障清除时刻的全部特征;方案4为故障清除后恢复过程中的3个采样时刻的全部特征;方案5为所提3个关键时刻的电压特征 U 和 θ ;方案6为所提3个关键时刻的功率特征 P_G 、 Q_G 、 P_L 、 Q_L 、 P_B 、 Q_B 。测试结果如表3所示。

表3 不同特征组合的测试结果

Table 3 Test results of different feature combinations

特征输入方案	$\lambda_A/\%$	$\lambda_G/\%$
方案1	99.58	99.55
方案2	98.45	98.41
方案3	99.11	99.14
方案4	99.32	99.34
方案5	97.71	97.85
方案6	97.28	97.25

由表3可知,本文所用方案1的时序特征组合显然优于方案2(单时刻)和方案3(两时刻)的评估精度。这表明故障前稳态、故障发生、故障清除3个时刻是捕捉暂态电压稳定特性的关键时序窗口。方案4反映了故障清除后恢复过程中的变化趋势,虽然其评估精度较高,但方案1能在更早的时刻得到评估结果。方案5因缺少功率特征,无法反映系统功率平衡与传输约束对电压恢复的影响;方案6则因缺少电压核心特征,难以直接捕捉电压失稳的动态特性,导致其评估精度较低。因此,选择方案1的特征作为模型的输入是合理的。基于方案1特征训练的模型,其准确率 $\lambda_A=99.58\%$,模型稳定性指标 $\lambda_G=99.55\%$,在所有特征组合中表现最佳。该特征集训练的模型可作为电力系统原始运行场景的高精度暂态电压稳定评估模型。

为了使评估模型适应新的运行场景,采用改进的McDalNet框架进行迁移学习,以实现模型的自适应更新。模型更新的总迭代次数设为60,特征提取器 g 和标签分类器 f 的初始状态从上述源域场景评估模型中获取。辅助分类器 f' 、 f'' 和特征提取器 g 之间采用梯度反转层实现对抗性优化,从而促进域不变特征的提取。为进一步优化对抗训练的平衡性,引入梯度反转层适应参数 α ,以动态调整梯度反转的强度。该系数随训练过程自适应调

整,计算公式如下:

$$\alpha = \frac{2}{1 + e^{-\epsilon k}} - 1 \quad (19)$$

式中: ϵ 为控制参数,通常取10。

梯度反转层通过将梯度乘 $-\alpha$ 来实现梯度反向传播及缩放。该系数自适应地从0增加至1,逐渐增强梯度反转的强度,不仅能实现对抗目标,还能避免在训练初期因梯度反转过强导致的振荡,从而稳定优化过程并提升模型在新场景中的泛化能力。

模型更新采用目标域训练数据与等量源域训练数据构成的融合数据集。然而,过多的样本量会增加样本生成及模型更新的耗时,不利于模型的快速更新。为此,以50个T1目标域场景训练样本为一组,测试了不同目标域训练样本数量对模型评估T1目标域测试集准确率的影响,结果如图4所示。




图4 目标域训练样本数量测试

Fig.4 Test of the number of training samples in the target domain

图4中,随着目标域训练样本数量的增加,评估模型的准确率呈上升趋势。当样本组数增加到8组时,准确率的变化逐渐趋于平稳,继续增加目标域样本数量对准确率的提升效果不大。同时,所需目标域样本数越多,样本生成时间及模型训练也会相应增加。因此,选择8组即400个目标域样本作为目标域训练数据的样本数量。

为了分析中心损失系数的敏感性,对比了不同系数值对模型性能的影响。通过调整不同的取值,评估模型在T1目标域场景下的测试结果如表4所示。结果显示,当 $\lambda=0.1$ 时,模型的准确率 λ_A 和稳定性指标 λ_G 均达到最高值;当 λ 偏离0.1时,模型性能逐渐下降。具体而言,当 $\lambda=1$ 时, λ_A 降至97.85%;当 $\lambda=0$ 时, λ_A 降至97.25%。因此将中心损失系数 λ 设为0.1。

表4 中心损失系数敏感性测试

Table 4 Sensitivity test of the center loss coefficients

中心损失系数 λ	$\lambda_A/\%$	$\lambda_G/\%$
0	97.25	97.20
0.01	98.10	98.08
0.05	99.01	99.06
0.10	95.55	95.55
0.50	98.43	98.42
1.00	97.85	97.82

为观察模型自适应更新过程中模型对源域和T1目标域场景的域对齐情况,采用t-SNE方法将特征提取器 g 输出的特征空间 \hat{S}^g 和 \hat{T}^g 降维到二维平面。样本分布随迭代次数的变化如图5所示。在模型更新训练开始前,源域和目标域特征分布部分相同,但也存在差异,两域分布呈现不一致性。经过多次特征提取器和辅助分类器的对抗训练后,特征分布逐渐接近并融合,最终在特征空间中,特征提取器提取到的不同场景特征分布趋于一致。这使得标签分类器能够适用于不同场景,从而提升了模型在场景切换后的评估性能。




图5 源域与目标域样本分布变化

Fig.5 Changes in the sample distribution of the source and target domains

模型更新前后对原场景和T1场景的评估结果如表5所示。表5中“未更新”一栏表示仅采用源域训练集训练模型的评估结果。此时,模型的特征提取器输出映射到二维空间如图5(a)所示,由于

此时模型仅适用于电力系统原始运行场景,因此对原场景测试样本有较高的评估精度。然而目标域特征分布与源域特征分布存在差异,导致直接采用原始模型评估场景切换后评估性能较差。具体表现为:模型准确率 λ_A 仅为87.95%,模型稳定性指标 λ_G 仅为87.73%。通过改进的McDalNet迁移学习方法进行模型更新后,对原场景测试集的评估结果显示: $\lambda_A=99.40\%$ 、 $\lambda_G=99.34\%$ 。与未更新前相比,变化很小,几乎不受影响。而对于T1目标域场景的测试集,评估性能显著提高,模型的准确率和稳定性指标分别提升了11.60%和11.82%。在原场景和T1场景下,模型均具有较高的评估精度。因此表明目标域和源域分布如图5所示逐渐实现了域对齐,标签分类器能够同时高精度识别不同运行场景的样本,提高了模型的泛化性能。

表5 模型更新前后评估结果对比

Table 5 Comparison of assessment results before and after model update

模型	场景	$\lambda_A/\%$	$\lambda_G/\%$
原始未更新模型	原始场景	99.58	99.55
	T1场景	87.95	87.73
改进McDalNet	原始场景	99.40	99.34
	T1场景	99.55	99.55

为体现暂态电压稳定问题,从评估模型的T1场景测试集中随机选取了一个暂态电压稳定样本及一个暂态电压失稳样本,如图6所示。

1)图6(a)为暂态电压稳定样本,其运行场景为:在100%标准负荷水平下,线路25—26上发生三相短路故障,故障位置距离母线25为线路25—26总长的80%,故障持续0.20s后被清除。在该场景中,负荷母线电压在故障清除后能够迅速恢复到0.8 p.u.以上。

2)图6(b)为暂态电压失稳样本,其运行场景为:在100%标准负荷水平下,线路9—39上发生三相短路故障,故障位置距离母线9为线路9—39总长的20%,故障持续0.25s后被清除。在该场景中,大部分负荷母线电压在故障清除后无法恢复到0.8 p.u.以上,且存在电压振荡问题。

3.3 持续学习能力测试

电力系统运行场景的频繁切换和更新会导致




图6 T1场景的暂态电压稳定及失稳样本

Fig.6 Transient voltage stability and instability samples in Scenario T1

拓扑结构的变化,例如线路和发电机因检修维护暂时脱网、负荷波动等变化可能频繁发生。为测试改进McDalNet的持续学习能力,基于T1—T3目标域场景训练集对模型进行连续更新,同时对对比了迁移学习中传统的TCA(迁移成分分析)^[19]、微调算法^[20]和文献[21]所提的改进DANN方法对模型更新的效果。这些方法用于更新模型的目标域样本数量均为400,与本文提出的方法保持一致。评估结果对比如图7所示。

由图7可见,随着运行场景的连续更新变化,TCA、微调算法和改进DANN的评估结果均存在较大波动。具体而言:TCA的特征提取仅关注不同样本分布的距离,而缺乏判稳性能考量,在所有方法中评估精度最低;微调算法在模型更新过程中容易遗忘已学知识;改进DANN虽然采用了域对抗策略,但其域分类器仍使用交叉熵损失,衡量不同运行场景特征分布差异的能力较弱,特征提取器提取到的域不变特征较少,因此在连续切换的运行场景下评估精度有所下降。相比之下,本文提出的方法在模型准确率 λ_A 及稳定性指标 λ_G 方面均表现最佳,并且在多场景切换下变化均较平稳,表现出较好的泛化性能。这是因为本文方法的辅助分类器采用切片 Wasserstein 距离构造 MCS D 替代函数,能够更细致地衡量不同域分布的差异。在与特征提取器的对抗学习策略中,该




图7 持续学习能力比较

Fig.7 Comparison of continual learning capability

方法能够更好地获取域不变特征,实现域对齐。因此,即使在少量目标域样本的情况下,也能自适应更新模型,适应电力系统场景的变化,维持较高的评估精度,具有较好的持续学习能力。

3.4 模型在复杂场景变化下的鲁棒性测试

为验证所提改进McDalNet模型在电力系统极端运行场景切换中的适应能力,本节通过以下三类场景测试模型的鲁棒性:新能源出力突变场景、多线路同时故障的N-2故障场景、场景回溯。

1) 新能源出力突变场景:在原始运行场景下,33号、34号、36号母线上的风机切出30%的容量。

2) 多线路同时故障场景:在新能源出力突变场景下,以下随机选择的4条线路(B3—B4、B10—B11、B16—B24、B26—B29)中,任意两条线路同时发生三相短路故障,故障位置分别在每条线路总长的2%、20%、40%、60%、80%及98%处。

3) 场景回溯:在多线路同时故障场景下,重新回到原始运行场景。

模型结构与参数与3.2节保持一致,在上述三

种连续切换场景下,模型的鲁棒性测试结果如表 6 所示。

表 6 模型在复杂场景变化下的评估结果

Table 6 Assessment results of the model under complex scenario variations

场景	$\lambda_A/\%$	$\lambda_G/\%$
新能源出力突变	99.47	99.48
多线路同时故障	99.32	99.44
场景回溯	99.53	99.49

由表 6 可知,所提模型在面对一些极端场景变化时,尽管评估准确率相较于原始运行场景略有下降,但仍然能够保持较高的评估精度。这表明由切片 Wasserstein 距离构造的 MCSD 替代函数能够有效捕捉极端场景与常规场景之间的特征分布差异。因此,改进的 McDalNet 模型在自适应更新过程中表现出良好的鲁棒性。此外,在场景回溯后,评估模型的准确率 λ_A 及稳定性指标 λ_G 有所提升,恢复到与原始评估模型相近的水平,说明改进的 McDalNet 模型在自适应更新过程中并未遗忘原始场景的特征分布,从而验证了该模型在复杂场景变化下的鲁棒性。

3.5 大规模电网的适用性测试

为进一步测试所提方法在大规模电力系统中的适用性,采用改进的南卡罗莱纳州 500 节点系统算例进行测试。在原始的南卡罗莱纳州 500 节点系统中,将 11 台同步发电机等容量替换为风力发电机组,同时将 8 台同步发电机等容量替换为太阳能发电机组。替换后,新能源的装机容量占系统总容量的 50.9%。

将系统负荷水平设置为标准负荷的 90%、100%、110%、120% 这四档水平;三相短路故障位置依次设置为各交流线距首端 2%、20%、40%、60%、80%、98% 处;故障持续时间分别设置为 0.1 s、0.2 s、0.3 s。通过上述设置共得到 33 552 个样本作为代表源域的原始运行场景样本,随机选择其中 70% 的样本作为源域训练集,其余作为源域测试集。目标域场景 T_{A1} 设置为在原始运行场景下,4 条交流线路(线路 B89—B187、B230—B285、B380—B493 和 B476—B486)因检修暂时断开;场景 T_{A2} 设置为在运行场景 T_{A1} 的基础上,切除 38 号、188 号和 466 号母线上的负荷,同时

145 号、224 号和 456 号母线上的发电机因检修暂时脱网;场景 T_{A3} 设置为在运行场景 T_{A2} 的基础上,将负荷水平增加到标准负荷的 125% 和 130%,435 号和 436 号母线上的同步发电机并网投入运行,所有同步发电机按额定容量比例调整相应出力。用于迁移学习的目标域训练样本数量、网络结构及模型相关参数与 3.2 节保持一致。

随着该算例运行场景从原始场景连续切换至目标域场景 T_{A3} ,采用改进的 McDalNet 持续更新评估模型,更新方式与 3.3 节相同,并与改进的 DANN 迁移学习算法进行对比。评估结果如表 7 所示。

表 7 改进的南卡罗莱纳州 500 节点系统的评估结果

Table 7 Assessment results of the modified 500-bus system in South Carolina

模型	场景	$\lambda_A/\%$	$\lambda_G/\%$
原始未更新模型	原始场景	99.02	98.76
	T_{A1} 场景	40.82	13.92
改进 DANN	T_{A1} 场景	94.42	93.96
	T_{A2} 场景	96.04	95.69
	T_{A3} 场景	95.13	94.58
改进 McDalNet	T_{A1} 场景	98.07	97.69
	T_{A2} 场景	98.35	98.19
	T_{A3} 场景	99.24	99.00

由表 7 可见,在大规模电网算例下,经源域数据训练的原始未更新模型同样对原始场景具有较高的评估精度,而在运行场景切换到 T_{A1} 后,准确率 λ_A 和模型稳定性指标 λ_G 均出现了显著下降。这说明针对具有高维特征的大电网,拓扑变化对暂态电压稳定评估模型性能的影响更为明显。若不对评估模型进行自适应更新,模型的可靠性将大大降低。通过所提改进的 McDalNet 迁移学习方法的自适应更新后,可以看到从 T_{A1} 场景到 T_{A3} 场景,准确率 λ_A 和模型稳定性指标 λ_G 均能达到与原始场景下相同的高精度评估水平。相比之下,改进的 DANN 迁移学习算法的评估性能始终落后于改进的 McDalNet。这表明所提方法对于大规模电网场景具有较好的适用性,模型依然具备较强的可持续学习能力和泛化性能。

3.6 模型耗时测试

为体现所提改进 McDalNet 模型的时间效率,本节在不同节点算例中对比了在新场景切换后,

所提模型以及重新训练模型两种更新方法使模型的评估准确率达到98.0%时的样本需求及样本生成耗时,如表8所示。

表8 模型的样本需求对比

算例	模型更新方法	样本生成数量/个	样本生成耗时/s
改进39节点	重新训练	1 400	1 238.5
	改进McDalNet	150	132.7
改进500节点	重新训练	5 600	4 721.8
	改进McDalNet	400	337.3

相较于重新训练模型,所提模型在新场景下的自适应更新所需样本量大大减少。在两个测试系统中,所提模型达到98.0%的准确率分别仅需150个和400个目标域样本,因此显著降低了生成目标域样本所需的时间。同时,还测试了所提模型在两个系统算例中场景切换的模型更新耗时及评估时间,结果如表9所示。随着系统节点数的增加,所提模型的更新耗时有所增长,但仍能够具备较快的更新效率。模型在线评估时,两个算例的平均单个样本评估耗时分别只需0.07 ms和0.16 ms,因此模型能够满足在线暂态电压稳定评估的要求。

表9 模型更新及评估耗时

算例	模型更新耗时/s	评估耗时/s	单样本评估耗时/ms
改进39节点	24.36	0.42	0.07
改进500节点	94.18	0.94	0.16

4 结论

针对电力系统运行场景频繁切换导致的暂态电压稳定评估模型性能显著下降问题,本文提出了一种基于改进McDalNet的电力系统暂态电压稳定自适应评估方法。该方法能够自适应对齐源域场景与目标域场景的样本分布,实现评估模型的更新,从而提高运行场景切换后的暂态电压稳定评估模型性能。在改进的含新能源机组的IEEE 39节点系统和美国南卡罗来纳州500节点系统的测试结果表明:

1)所提方法通过改进损失函数,能够更好衡量邻域场景的特征分布差异,并通过对抗训练方式促进域对齐,提取不同运行场景的公共特征分

布,从而实现暂态电压稳定评估模型的有效更新。

2)所提方法显著提升了电力系统运行场景切换后暂态电压稳定评估模型的准确率和稳定性。在运行场景连续频繁切换的情况下,评估更新模型的评估性能始终优于传统的迁移学习(如TCA、微调算法)及已有的改进DANN方法,具备较强的可持续学习能力。

3)改进的McDalNet更新模型具备较好的泛化性能,对于复杂场景变化及大规模电力系统均具备较强的可靠性和适用性。

参考文献

- [1] 杨凯璇,卢国强,傅国斌,等.基于关键影响因素量化分析和HGNN的暂态稳定评估[J].浙江电力,2025,44(7):33-43.
YANG Kaixuan, LU Guoqiang, FU Guobin, et al. A transient stability assessment method using quantitative analysis of key influencing factors and HGNN[J]. Zhejiang Electric Power, 2025, 44(7): 33-43.
- [2] 管敏渊,姚瑛,吴圳宾,等.基于RBF神经网络的储能VSG控制策略优化[J].浙江电力,2024,43(3):55-64.
GUAN Minyuan, YAO Ying, WU Zhenbin, et al. Optimization of energy storage VSG Control strategy based on RBF neural networks[J]. Zhejiang Electric Power, 2024, 43(3): 55-64.
- [3] 杨金洲,李业成,熊鸿韬,等.新能源接入的受端电网暂态电压失稳高风险故障快速筛选[J].电工技术学报,2024,39(21):6746-6758.
YANG Jinzhou, LI Yecheng, XIONG Hongtao, et al. A fast screening method for the high-risk faults with transient voltage instability in receiving-end power grids interconnected with new energy[J]. Transactions of China Electrotechnical Society, 2024, 39(21): 6746-6758.
- [4] 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.
- [5] GHAEDI S, ABAZARI S, ARAB MARKADEH G. Transient stability improvement of power system with UPFC control by using transient energy function and sliding mode observer based on locally measurable information [J]. Measurement, 2021, 183: 109842.
- [6] DUCHESNE L, KARANGELOS E, WEHENKEL L. Recent developments in machine learning for energy sys-

- tems reliability management[J].Proceedings of the IEEE, 2020,108(9):1656-1676.
- [7] 陈宜尊,朱容更,邓晗应,等.基于支持向量机的机载自耦变压整流器故障诊断方法[J].电气技术,2024,25(8):41-46.
CHEN Yizun, ZHU Ronggeng, DENG Hanying, et al. Fault diagnosis method for airborne autotransformer rectifier units based on support vector machine [J]. Electrical Engineering, 2024, 25(8): 41-46.
- [8] ZHANG S Y, YU J J Q. Bayesian deep learning for dynamic power system state prediction considering renewable energy uncertainty[J]. Journal of Modern Power Systems and Clean Energy, 2022, 10(4): 913-922.
- [9] 李蔚,吴懿范,毛静宇,等.基于改进随机森林算法的汽轮机振动故障诊断研究[J].浙江电力,2024,43(9):107-116.
LI Wei, WU Yifan, MAO Jingyu, et al. Research on diagnosis for vibration faults in steam turbines using IRF algorithm[J]. Zhejiang Electric Power, 2024, 43(9): 107-116.
- [10] 武宇翔,韩肖清,牛哲文,等.基于变权重随机森林的暂态稳定评估方法及其可解释性分析[J].电力系统自动化,2023,47(14):93-104.
WU Yuxiang, HAN Xiaoqing, NIU Zhewen, et al. Transient stability assessment method based on variable weight random forest and its interpretability analysis[J]. Automation of Electric Power Systems, 2023, 47(14): 93-104.
- [11] 石重托,姚伟,黄彦浩,等.基于SE-CNN和仿真数据的电力系统主导失稳模式智能识别[J].中国电机工程学报,2022,42(21):7719-7731.
SHI Zhongtuo, YAO Wei, HUANG Yanhao, et al. Power system dominant instability mode identification based on convolutional neural networks with squeeze and excitation block and simulation data[J]. Proceedings of the CSEE, 2022, 42(21): 7719-7731.
- [12] 解治军,张东霞,韩肖清,等.基于改进长短期记忆网络的电力系统暂态稳定评估方法研究[J].电网技术,2024,48(3):998-1007.
XIE Zhijun, ZHANG Dongxia, HAN Xiaoqing, et al. Research on transient stability assessment method of power system based on improved long short term memory network[J]. Power System Technology, 2024, 48(3): 998-1007.
- [13] 卫志农,李超凡,丁爱飞,等.基于Tri-training-SSAE半监督学习算法的电力系统暂态稳定评估[J].电力自动化设备,2023,43(7):110-116.
WEI Zhinong, LI Chaofan, DING Aifei, et al. Power system transient stability assessment based on Tri-training-SSAE semi supervised learning algorithm [J]. Electric Power Automation Equipment, 2023, 43(7): 110-116.
- [14] SU T, LIU Y B, ZHAO J B, et al. Deep belief network enabled surrogate modeling for fast preventive control of power system transient stability[J]. IEEE Transactions on Industrial Informatics, 2022, 18(1): 315-326.
- [15] 刘雨晴,刘墨,王小君,等.融合同步知识和时空信息的电力系统暂态稳定评估框架[J].电网技术,2025,49(6):2334-2346.
LIU Yuqing, LIU Zhao, WANG Xiaojun, et al. Power system transient stability assessment framework based on fusion of synchronization knowledge and spatial-temporal information [J]. Power System Technology, 2025, 49(6): 2334-2346.
- [16] 王涛,杨远,申冰洁,等.面向运行场景变化的方差引导式域适应暂态稳定评估[J].电工技术学报,2025,40(21):6970-6983.
WANG Tao, YANG Yuan, SHEN Bingjie, et al. Variance-guided domain-adaptive transient stability assessment framework [J]. Transactions of China Electrotechnical Society, 2025, 40(21): 6970-6983.
- [17] LI F, WANG Q, TANG Y, et al. Hybrid analytical and data-driven model based instance-transfer method for power system online transient stability assessment [J]. CSEE Journal of Power and Energy Systems, 2024, 10(4): 1664-1675.
- [18] TIAN Y, WANG K Y, OLUIC M, et al. A data-driven methodology for transient stability assessment based on broad learning system [C]//2020 IEEE Power & Energy Society General Meeting (PESGM). August 2-6, 2020, Montreal, QC, Canada: IEEE, 2020: 1-5.
- [19] REN C, XU Y. Transfer learning-based power system online dynamic security assessment: using one model to assess many unlearned faults [J]. IEEE Transactions on Power Systems, 2020, 35(1): 821-824.
- [20] KIM J, LEE H, KIM S, et al. Transient stability assessment using deep transfer learning [J]. IEEE Access, 2023, 11: 116622-116637.
- [21] 申锦鹏,杨军,李蕊,等.基于改进域对抗迁移学习的电力系统暂态稳定自适应评估[J].电力系统自动化,2022,46(23):67-75.
SHEN Jinpeng, YANG Jun, LI Rui, et al. Self-adaptive transient stability assessment of power system based on improved domain adversarial transfer learning [J]. Automation of Electric Power Systems, 2022, 46(23): 67-75.
- [22] 王兴华,杨皓文,麻玉林,等.基于改进迁移学习的高压断路器新增类别故障识别方法[J].高压电器,2025,61(10):106-116.
WANG Xinghua, YANG Haowen, MA Yulin, et al. Fault identification method for newly added categories in high voltage circuit breakers based on improved transfer learn-

- ing[J].High Voltage Apparatus,2025,61(10):106-116.
- [23] 龙禹,王雨薇,任禹丞,等.基于时序迁移策略的空调负荷需求响应潜力评估[J].电力需求侧管理,2025,27(3):11-17.
- LONG Yu, WANG Yuwei, REN Yucheng, et al.Potential evaluation of air conditioning load demand response based on time-sequential migration strategy [J].Power Demand Side Management,2025,27(3):11-17.
- [24] 焦昊,赵佳伟,韦磊,等.基于深度迁移学习的电力系统暂态状态估计[J].电力建设,2025,46(1):97-106.
- JIAO Hao, ZHAO Jiawei, WEI Lei, et al.Transient state estimation for power system based on deep transfer learning[J].Electric Power Construction,2025,46(1):97-106.
- [25] 阮睿,朱清,郭登辉,等.基于迁移学习的风电并网系统次/超同步振荡紧急切机策略[J].智慧电力,2024,52(11):23-31.
- RUAN Rui, ZHU Qing, GUO Denghui, et al.Emergency tripping strategy for sub/supersynchronous oscillation in wind power integrated system based on transfer learning [J].Smart Power,2024,52(11):23-31.
- [26] ZHANG Y, DENG B, TANG H, et al. Unsupervised multi-class domain adaptation: theory, algorithms, and practice [J].IEEE Transactions on Pattern Analysis and Machine Intelligence,2022,44(5):2775-2792.
- [27] LEE C Y, BATRA T, BAIG M H, et al.Sliced Wasserstein discrepancy for unsupervised domain adaptation [C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR).June 15-20,2019,Long Beach,CA,USA:IEEE,2020:10277-10287.
- [28] 国家市场监督管理总局,国家标准化管理委员会.电力系统安全稳定导则:GB 38755—2019[S].北京:中国标准出版社,2019.
- [29] 国家市场监督管理总局,国家标准化管理委员会.电力系统安全稳定计算规范:GB/T 40581—2021[S].北京:中国标准出版社,2021.
- [30] WU J Y, LI L S, SHI F S, et al.A two-stage power system frequency security multi-level early warning model with DS evidence theory as a combination strategy [J].International Journal of Electrical Power & Energy Systems,2022,143:108372.
-
- 收稿日期:** 2025-11-24; **修回日期:** 2025-12-27
- 作者简介:**
黄莹(1989),女,工学博士,高级工程师,主要从事电力系统电压安全稳定分析与评估方面的研究工作。
(本文编辑:方明霞)