

融合样本加权迁移学习的暂态电压稳定评估模型

郑瀚林, 温步瀛, 王怀远

(福州大学 电气工程与自动化学院, 福州 350108)

摘要: 针对暂态电压稳定评估模型因实际故障样本与训练样本的分布存在偏差而导致的精度下降问题, 提出一种融合样本加权迁移学习的暂态电压稳定评估模型。首先, 采用长短期记忆网络进行特征提取, 借助特征提取器与域判别器的对抗训练机制, 实现源域与目标域样本特征空间的对齐。其次, 基于源域训练样本与目标域故障样本的相似度指标, 在对抗训练过程中为源域样本动态分配权重, 以强化关键样本在迁移过程中的作用。最后, 在 IEEE 39 节点系统中进行仿真实验, 结果表明, 所提模型能够有效提升评估精度与泛化性能。

关键词: 暂态电压稳定评估; 样本加权; 迁移学习; 长短期记忆网络

DOI: 10.19585/j.zjdl.202602004

开放科学(资源服务)标识码(OSID):



A transient voltage stability assessment model integrating sample-weighted transfer learning

ZHENG Hanlin, WEN Buyang, WANG Huaiyuan

(College of Electrical Engineering and Automation, Fuzhou University, Fuzhou 350108, China)

Abstract: To address the issue of accuracy degradation in transient voltage stability assessment models caused by the distribution discrepancy between actual fault samples and training samples, this paper proposes a novel assessment model that integrates sample-weighted transfer learning. Firstly, long short-term memory (LSTM) networks are employed for feature extraction. An adversarial training mechanism between the feature extractor and a domain discriminator is utilized to align the feature spaces of samples from the source and target domains. Secondly, based on similarity metrics between the source domain training samples and the target domain fault samples, dynamic weights are assigned to the source domain samples during the adversarial training process. This reinforces the contribution of critical samples to the transfer learning. Finally, simulation experiments conducted on the IEEE 39-bus system demonstrate that the proposed model effectively enhances assessment accuracy and generalization performance.

Keywords: transient voltage stability assessment; sample weighting; transfer learning; LSTM networks

0 引言

随着电力系统规模不断扩大, 电网故障时的暂态电压稳定性问题日益严峻。暂态电压稳定性不仅直接关系到电网的安全性和可靠性, 也对电力系统的正常运行产生重要影响^[1-3]。近年来, 人工智能技术的快速发展促进了其在电力系统暂态电压稳定分析中的应用^[4]。与传统的暂态电压稳定评估方法(如基于数值计算的时域仿真法^[5-6]和理论推导的直接法^[7]等)相比, 基于机器学习的暂态电压稳定评估方法凭借强大的数据驱动能力, 在评估精度和响应速度方面展现出显著优势^[8]。

然而, 传统机器学习方法通常需在测试和训练数据分布相同且训练样本充足的条件下, 方可达到较高的评估精度^[9]。在实际电力系统运行中, 电网拓扑结构动态变化、新能源大量接入导致运行场景复杂化, 测试数据与训练数据间的分布差异往往难以避免^[10]; 同时, 受故障记录不完整、数据采集成本高等因素制约, 获取充足高质量训练样本存在困难^[11]。这些问题易导致模型出现过拟合或泛化能力弱等问题, 严重制约了评估模型的准确性和可靠性。

迁移学习作为机器学习的重要分支, 能够将源任务中学习到的知识与经验有效迁移到目标任务中, 突破传统机器学习的限制, 实现跨领域的知识迁移, 在暂态电压稳定性预测领域具有广阔的应用前景^[12]。文献[13]提出一种基于迁移学习

的多模态特征融合模型, 通过结合时域特征加权策略与MMD(最大均值差异)来提高跨工况故障识别能力。文献[14]提出一种基于深度信念网络的主动迁移学习方法, 通过主动学习策略选取关键样本, 并根据MMD大小选择不同迁移方案, 以最小化源域与目标域数据分布差异。文献[15]提出一种基于MRSE-CNN(融合多尺度残差挤压激励机制的卷积神经网络)的多任务暂态稳定自适应评估方案, 采用模型参数微调的迁移学习方法实现模型的自适应更新。文献[16]提出一种基于深度自适应网络迁移的暂稳评估模型更新框架, 通过动态调整边缘分布与条件分布权重来更新模型。尽管上述主流迁移方法在跨域知识传递过程中引入了对源域和目标域样本类别进行样本加权的思路, 但未能充分考虑源域训练样本与真实故障样本间的个体差异。当训练集中包含大量与实际故障样本特征差异显著的样本时, 若进行无差别的知识迁移, 可能导致模型学习公共知识不理想, 迁移效果降低, 甚至可能对目标域样本的泛化性能产生负面影响^[17]。

需要指出的是, 当前迁移学习在电力系统稳定分析中的研究主要聚焦于暂态功角稳定性评估, 通常以关键发电机组的功角与角速度作为核心特征量。文献[18]提出一种改进域对抗迁移学习的电力系统暂态稳定评估方法, 通过梯度翻转层引入域对抗训练机制, 在特征空间最小化源域和目标域之间的分布差异, 实现暂态功角稳定的自适应评估。文献[19]通过详细对比暂态功角与电压稳定性预测的方法与特点, 指出二者在判别依据与关键影响因素方面存在显著差异。目前暂态电压稳定性分析的研究仍存在较大探索空间。该领域以系统各节点电压幅值与相角作为研究对象, 其分析范畴更具全局性。鉴于节点电压动态特性与发电机组功角变化机制存在显著差异, 将迁移学习方法引入暂态电压稳定性分析具有重要的理论价值和现实意义。然而, 针对暂态电压稳定性分析中存在电压节点多、特征维数高、计算复杂等问题, 传统分布度量方法(如MMD)在迁移学习域间分布准确度量方面仍存在局限性。文献[20]提出一种两阶段迁移学习框架, 指出传统MMD方法在复杂域间距离衡量问题中的不足, 其对高阶特征的可迁移能力相对有限。具体表现为: 一

方面, 在高维特征空间中, 各维度的重要性可能不同, MMD的单一核函数难以有效捕捉多尺度的分布差异, 削弱了对复杂分布结构的刻画能力; 另一方面, 在高维条件下, MMD的估计方差增大, 统计功效下降, 易使分布差异被掩盖。此外, MMD对核参数高度敏感, 参数选择不当将严重影响其度量准确性, 进而降低模型性能。

为应对上述挑战, 本文针对暂态电压稳定评估问题, 构建了融合样本加权迁移学习的评估模型。首先, 所提模型在迁移训练前, 通过量化源域样本与目标域样本间的相似度, 优先选择与目标域样本分布差异小的源域训练样本参与迁移。其次, 在分布度量方法的选择上, 本文基于MMD理论, 引入MK-MMD(多核最大均值差异)方法, 通过多核函数融合以精准刻画数据分布, 优化域间特征对齐, 从而提升迁移学习模型在暂态电压稳定评估中的预测精度。在实际电力系统测试中, 所提模型在跨域知识迁移性能与评估准确性方面均展现出显著优势。

1 样本加权思路

基于GAN(生成对抗网络)中生成器与判别器相互对抗完成模型训练的思想^[21], 域对抗迁移模型将对主体替换为特征提取器与域判别器, 其基本框架如图1所示。在该框架中, 特征提取器与域判别器通过对抗博弈, 促使特征提取器学习到源域与目标域之间的共享特征空间^[22]; 当域判别器无法有效区分样本来自源域还是目标域时, 将由源域训练得到的标签分类器应用至目标域中, 实现对目标域样本的准确分类。

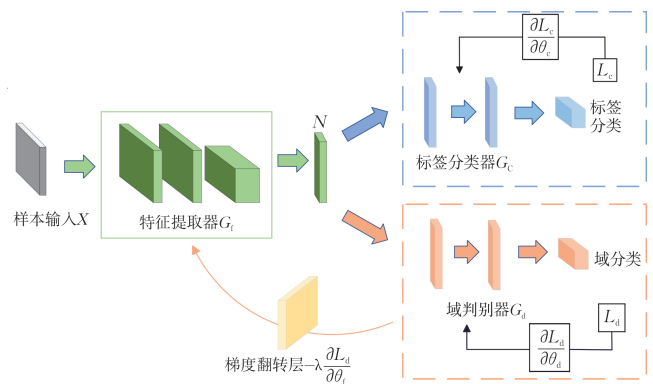


图1 域对抗迁移模型框架

Fig.1 Structure of domain-adversarial neural network

传统域对抗迁移模型在对齐源域与目标域特征分布时, 通常默认不同源域样本在迁移任务中的作用相同, 未能充分考虑源域样本与目标域样本之间的相似度和适配程度。从理论层面看, 该假设忽视了数据分布的差异性, 导致模型在构建跨域映射关系时, 无法精准捕捉源域与目标域间的相似对应关系。在实际应用中, 源域样本对目标域的迁移价值存在显著差异, 部分与目标域分布偏离较大的源域样本若在对抗训练中占据主导, 将可能导致学习到的特征空间偏离目标域的真实分布, 从而削弱模型在目标域上的预测性能。

针对以上问题, 本文提出一种融合样本加权的域对抗迁移模型, 通过联合特征级迁移与样本级选择性迁移, 在特征空间对两域样本间分布进行度量, 并根据空间分布度量结果对源域样本进行相似度评估与权重分配, 优先选择与目标域分布更接近的源域样本参与对抗训练。这种“度量-筛选-迁移”机制不仅能够有效对齐源域与目标域的特征分布, 还能抑制低价值源域样本对模型训练的干扰, 显著提升模型对目标域数据分布的适应能力与泛化性能。特征映射过程如图2所示。

如图2(a)所示, 传统对抗迁移模型为所有源域样本赋予相同权重。若与目标域分布偏离较大的源域样本被赋予与目标域相似度高的源域样本相同的权重, 将导致模型在特征映射过程中无法充分学习到两域样本的公共判别特征。公共特征越少, 部分目标域失稳(稳定)特征会错误地对齐至源域样本的稳定(失稳)特征。这种错误将进一步导致模型从源域学习到的分类边界在目标域应用时发生偏差, 如图2(a)中黄色分类边界所示, 少数目标域样本被错误分类, 模型的迁移效果不理想。

如图2(b)所示, 在提高与目标域高相似度样本的权重, 同时降低分布差异较大样本的占比后, 引入关键样本加权后的改进模型在特征对齐时可充分学习到两域样本间的公共判别性特征, 两域稳定样本和失稳样本的特征能有效对齐, 经源域训练得到的标签分类器可更好地应用于目标域中, 使得图2(b)中对应的黄色分类边界能正确区分稳定和失稳样本。




图2 特征映射过程

Fig.2 Feature mapping process

2 关键样本加权过程

本文在域对抗迁移模型的基础上, 提出了一种融合样本加权的对抗迁移模型。该模型引入“度量-筛选-迁移”的样本处理策略, 通过对样本进行筛选与加权, 进一步优化迁移学习效果。在该策略中, 关键样本的选择依赖于对源域与目标域样本的相似度判别, 这通常需要借助空间分布度量方法(如MMD)对样本间相似度进行评估, 在特征空间距离分布越接近的两域样本, 其相似度越高。

然而, 当将MMD等传统空间分布度量方法应用于暂态电压稳定性评估场景时, 由于暂态电压母线节点多且特征维数高, MMD采用的单一核函数难以准确衡量特征空间的分布距离。因此, 针对暂态电压变化特征, 选择合适且精确的分布度量方法, 显得尤为重要。下文将详细阐述本文所采用的度量方法以及样本加权过程。

2.1 关键样本选取

与主要聚焦于发电机相关参数、复杂性与数据量相对较低的暂态功角稳定性分析不同, 暂态电压稳定分析需处理涉及大量节点的电压数据, 复杂性与数据规模更高。因此, 需选取合适且精确的度量方法对两域样本间相似度进行量化评估。MMD为一种基于RKHS(再生核希尔伯特空间)理论的非参数化分布距离度量方法^[23]。该方法将数据分布嵌入到RKHS中, 通过计算分布在特征空间中均值向量之间的距离, 定量评估分布间差异。相较于传统距离度量方法, MMD无需对数据分布作先验假设, 在数据分布的相似度评估中通常展现出良好的鲁棒性与有效性。然而, MMD采用单一核函数构建特征空间, 其对数据中多尺度和多

层次分布差异的捕捉能力有限。当处理结构复杂和特征维度高的数据集时，易受核函数选择的影响，从而难以充分挖掘数据的潜在分布特征，在模型泛化性能上存在局限性。

为克服传统MMD的局限性，本文采用MK-MMD方法。其核心优势在于突破了单一核函数的表达瓶颈，通过将多个不同核函数进行线性组合，构建更为灵活且自适应的特征空间映射机制。这种多核融合策略能够有效捕捉数据中不同尺度和层次的结构特征与分布差异，在处理复杂高维数据时，不仅增强了模型对数据分布的刻画能力，还显著提升了模型的泛化性能。其计算公式如下所示：

$$D_{\text{MK-MMD}}^2 = \max_{\{\beta_p\}} \left[\frac{1}{n^2} \sum_{i,j} k_{\text{mk}}(x_i^s, x_j^s) - \frac{2}{nm} \sum_{i,j} k_{\text{mk}}(x_i^s, x_j^t) + \frac{1}{m^2} \sum_{i,j} k_{\text{mk}}(x_j^t, x_i^t) \right] \quad (1)$$

式中： $D_{\text{MK-MMD}}$ 为两域样本间多核最大均值差异的整体度量； $D_{\text{MK-MMD}}^2$ 为在RKHS中源域与目标域均值嵌入向量之间的平方欧氏距离，当该数值为0时表明两个分布完全一致； $k_{\text{mk}}(x, y)$ 为自适应加权后的核函数； β_p 为核函数的权重系数； x^s 和 x^t 分别为源域、目标域样本； i 和 j 为样本的索引； n 和 m 分别为源域、目标域的样本数量。

经上述计算得到的样本分布距离值越小，表明所输入两域样本之间的相似度越高。相应地，在域对抗迁移过程中提高对应源域样本的权重值，进一步凸显出与目标域分布差异小的关键源域样本在迁移过程中的价值。

2.2 关键样本加权

在2.1节计算出两域样本间的分布距离后，进一步将输入源域故障样本与目标域的分布度量结果转化为权重并进行归一化：

$$\{\omega_1, \omega_2, \dots, \omega_n\}_l = \frac{1}{\sum_{i=1}^m \frac{1}{D_{\text{MK-MMD}}(X_{s_i}, X_t)}} \frac{1}{D_{\text{MK-MMD}}(X_{s_l}, X_t)} \quad (2)$$

式中： X_s 和 X_t 分别为输入的源域、目标域故障样本集； m 为源域故障类型总数； l 为故障类型索引值； n 为源域某一线路故障时不同工况的样本数量。

根据 $D_{\text{MK-MMD}}$ 更改不同源域样本在域对抗迁移模型域判别损失中的权重^[24]。针对不同源域故障样本修改权重后的域判别损失 L_d 表达如下：

$$L_d = \omega_i d_i \log \frac{1}{G_D[G_F(x_i)]} + (1 - d_i) \log \frac{1}{1 - G_D[G_F(x_i)]} \quad (3)$$

式中： $G_F(x_i)$ 为通过特征提取器所提取的样本特征； G_D 为域判别器，判别特征来源； d_i 为第 i 个样本的领域标签，源域为1，目标域为0； ω_i 为对应源域故障线路样本计算得到的权重赋值。

样本加权过程如图3所示， x_s 和 x_t 分别为输入的源域、目标域样本集， z_s 和 z_t 分别为提取后的源域、目标域特征， ω 为经相似度结果转化后的权重。首先，采用LSTM(长短期记忆网络)进行特征提取。然后，引入MK-MMD域间分布度量策略，对源域样本与目标域样本之间的分布相似度进行评估。最后，将相似度评估结果经归一化处理作为样本权重，引导对抗训练过程中源域样本的重要性分配。具体而言，在域判别过程中针对每一个源域样本，根据相似度评估结果调整其在损失函数中的权重系数，降低大差异样本对模型迁移效果的干扰。

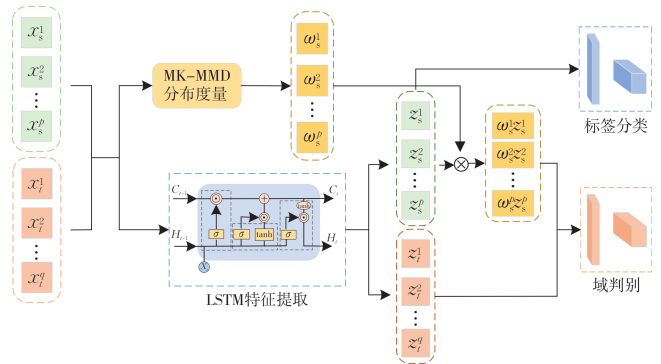


图3 样本加权过程

Fig.3 Workflow of the sample weighting process

通过上述样本加权过程，优先迁移与目标域相似度较高的源域样本，使得由源域训练得到的分类边界能更好地应用于目标域中，模型的迁移效果得到显著提升。

3 仿真实验

3.1 参数设置

本文利用PSD-BPA仿真生成了不同运行状

态、故障点、故障类型及故障持续时间场景下的故障样本, 并记录各节点受扰后不同时间段的电压和相角变化信息, 以此作为样本集的特征。

在 IEEE 39 节点系统中进行仿真, 共生成 12 872 个故障样本, 包括 6 899 个稳定样本和 5 971 个失稳样本; 系统运行负荷为 90%~110% 的额定负荷, 以 5% 为增量, 共 5 种工况; 故障类型均为永久性三相短路, 故障点分别在线路的 10%、50% 和 90% 处。选择故障清除时刻及清除后第 1~10 个采样周波的各母线节点电压幅值和相角值作为样本特征。系统频率为 60 Hz, 故障持续时间为 6~18.5 个周波, 以 0.5 个周波为间隔进行采样。按 4:1 的比例将样本划分至训练集和测试集。训练集包含来自源域的标注样本与少量目标域标注样本, 用于模型更新; 测试集则由目标域中未参与训练的样本构成, 用于评估模型在目标域上的泛化能力。IEEE 39 节点系统仿真参数如表 1 所示。

表 1 IEEE 39 节点系统仿真参数

Table 1 Simulation parameters for IEEE 39-bus system

参数名称	参数细节
故障线路	33 条输电线路
故障类型	永久性三相短路
故障点	每条线路的 10%、50% 和 90% 处
运行负荷	90%~110%
故障持续时间	6~18.5 个周波
特征采样时间	故障清除时刻及故障清除后 1~10 个周波

为更加直观地表征用于深度模型训练的电力故障数据的稳定性标签, 以系统受扰后负荷母线电压能否在 10 s 内恢复到 0.8 p.u. 作为暂态电压稳定判据^[25]。若系统稳定, 令其暂态电压稳定标签为 1; 反之, 若系统暂态失稳, 令其标签为 0。

通过式(4)中 3 个评估精度指标对所提模型的有效性进行验证。

$$\begin{cases} P_{AC} = \frac{T_P + T_N}{T_P + F_N + T_N + F_P} \times 100\% \\ P_{FD} = \frac{F_P}{F_P + T_N} \times 100\% \\ P_{FA} = \frac{F_N}{T_P + F_N} \times 100\% \end{cases} \quad (4)$$

式中: P_{AC} 为模型评估准确率; T_P 和 T_N 分别为稳

定、失稳样本被准确评估的数量; F_P 和 F_N 分别为失稳、稳定样本被误判的数量; P_{FA} 为稳定样本的误判率; P_{FD} 为失稳样本的误判率。

实验以 Python 作为编程语言, 所采用基础模型为 4 层 LSTM, 隐藏层维度为 64, 在 LSTM 层之后连接全连接层; 标签分类器由 1 个全连接层组成, 输入维度为 64, 输出维度为 2; 域判别器包含梯度翻转层和 3 个全连接层, 输入维度为 64, 隐藏层维度为 64, 输出维度为 2; 批大小设置为 32, 模型初始学习率为 0.001, 使用 Adam 优化器进行训练。采用学习率调整策略, 以每 20 个 Epoch 为 1 个步长, 每次步长到达时若模型性能不再提升, 将学习率乘以 0.5 进行衰减。训练的最大 Epoch 数为 100 次。

3.2 迁移性能对比

为准确评估源域与目标域间样本分布差异, 本文随机选取 IEEE 39 节点系统中 4 条故障线路样本作为目标域, 其余线路作为源域进行迁移仿真, 以比较不同分布度量方法下的模型迁移性能。迁移性能对比如表 2 所示。

表 2 不同分布度量方法下评估精度对比

Table 2 Performance comparison using different distribution metrics

度量方法	模型评估精度指标			%
	P_{AC}	P_{FD}	P_{FA}	
传统迁移(无度量)	90.51	13.18	3.13	
欧氏距离	93.27	10.00	0.89	
余弦距离	93.91	6.50	5.36	
KL 散度	94.23	9.00	0.28	
MMD	94.87	8.00	0.28	
MK-MMD	95.51	7.00	0.28	

由表 2 可知, 与传统对抗迁移方法相比, 融合不同分布度量方法的改进策略均能显著提升模型的评估精度, 并有效降低误判率。欧氏距离、余弦距离和 KL(Kullback-Leibler) 散度量方法在评估效果上略逊于 MMD 方法; MK-MMD 方法在 MMD 的基础上, 通过多核函数组合强化了对数据多尺度特征的代表能力, 能更精准地刻画高维空间中数据特征的分布差异, 迁移性能最优, 进一步验证了 MK-MMD 方法在暂态电压稳定性评估任务中的适用性和优越性。

3.3 关键样本加权有效性分析

选取 4 条故障线路样本 (bus6-7、bus2-bus3、bus15-bus16、bus26-bus29) 作为源域数据集, 8 条故障线路样本 (10-13、4-5、3-18、17-18、16-24、21-22、26-27、26-28) 作为目标域, 开展关键样本加权有效性分析。

针对不同目标域故障样本, 源域各故障线路样本经相似度评估后的权重变化情况如图 4 所示; 纵坐标为对应不同目标域线路时, 各源域故障线路样本所占权重大小; 横坐标为目标域线路名称。由图 4 可知, 融合样本加权的改进方案从两域样本间的相似度出发, 针对不同目标域线路, 提高源域中与目标域相似样本在迁移过程中的权重。以目标域线路 17-18 为例, 源域故障线路样本 bus15-bus16 经评估加权后权重约为 80%; 与对应目标域样本特征分布距离远且相似度低的源域样本 bus26-bus29 经评估加权后权重降至约为 5%。该方法凸显了关键源域样本的迁移价值, 针对不同目标域线路样本, 不同源域样本的权重值有明显差异。




图 4 源域线路样本权重变化情况

Fig.4 Weight variation of line samples in the source domain

传统对抗迁移模型和引入关键样本加权后的改进对抗迁移模型的评估准确率变化情况如图 5 所示, 纵坐标为模型的评估准确率 P_{AC} , 横坐标为不同目标域线路名称。未进行关键样本加权的传统对抗迁移模型中, 4 条源域故障线路样本的权重占比均为 25%。由图 5 可知, 改进后的对抗迁移模型评估准确率有显著提升, 平均提升约 10%, 进一步验证了本文所提方法的有效性。




图 5 引入关键样本加权前、后模型评估准确率对比
Fig.5 Model prediction accuracy comparison before and after key sample weighting

鉴于此, 在实际电力系统的应用中, 可预先评估源域样本与目标域线路样本间的相似度, 并根据分布度量结果动态调整各源域样本在迁移过程中的权重分配, 以增强模型的暂态电压稳定评估性能。

3.4 泛化性能评估

为评估所提方法的泛化性能, 选取各类浅层学习模型和深度学习模型作为特征提取网络, 在 IEEE 39 节点系统上开展暂态电压稳定性评估实验。实验中随机选取 4 条故障线路样本作为目标域, 其余线路样本作为源域。采用的浅层学习模型包括 SVM (支持向量机) 和 DNN (深度神经网络), 深度学习模型包括 SAE (堆叠自编码器)、CNN (卷积神经网络) 和 LSTM。在特征提取网络中加入融合样本加权的域对抗模型, 进行对比分析。具体参数设置如下: SVM 采用线性核函数, 惩罚系数 $c=50$, 核系数 $\gamma=0.001$; DNN 采用 2 层全连接层, 激活函数 ReLU; SAE 采用 3 层自编码器, 中间层维度 64; CNN 为 2 组卷积-池化层, 批大小为 32。泛化性能对比实验结果如表 3 所示。

由表 3 可知, 深度学习模型在各项指标中展现出显著优势。引入本文所提出的融合样本加权的域对抗迁移模型后, 各类机器学习模型的评估准确度均有不同程度的提升, 其中以 LSTM 模型的提升效果最为显著, 模型评估效果最优。综上, 本文所提方法在多种机器学习模型上具有良好的

表3 泛化性能对比实验结果

Table 3 Comparative results of generalization performance

模型	迁移前			迁移后		
	P_{AC}	P_{FD}	P_{FA}	P_{AC}	P_{FD}	P_{FA}
SVM	87.69	13.94	10.25	93.43	9.82	3.27
DNN	87.42	13.39	9.00	93.62	9.13	2.56
SAE	88.15	12.12	5.47	94.89	7.36	1.12
CNN	88.38	12.50	4.61	95.03	7.44	0.86
LSTM	88.73	12.00	3.68	95.51	7.00	0.28

泛化性能。

4 结论

针对电网实际故障样本与训练样本间分布偏移导致模型评估精度下降的问题,本文构建了融合样本加权迁移学习的暂态电压稳定评估模型。该模型依据MK-MMD计算得到的样本相似度指标,自适应地为源域训练样本分配权重,从而强化关键源域样本对模型评估结果的影响。在IEEE 39节点系统上的仿真实验验证了本文模型的有效性,并得出以下结论:

1)本文模型通过抑制分布差异较大的样本在迁移学习过程中的负面影响,有效提升了模型的整体迁移性能。实验结果表明,与普通深度学习模型和传统对抗迁移模型相比,本文模型的评估准确率分别提升了6.78%和5%。

2)基于MK-MMD的度量方法通过多个不同核函数的线性组合,能够有效捕捉数据多尺度和多层次的分布特征,在特征更为复杂的暂态电压稳定评估过程中表现出更好的适应性。与单核的MMD度量方法相比,采用MK-MMD度量方法使得模型评估准确率进一步提升了0.64%,验证了多核组合机制在提升分布差异度量的准确性方面的优势。

参考文献

- [1] 韩肖清,李廷钧,张东霞,等.双碳目标下的新型电力系统规划新问题及关键技术[J].高电压技术,2021,47(9):3036-3046.
HAN Xiaoqing, LI Tingjun, ZHANG Dongxia, et al. New issues and key technologies of new power system planning under double carbon goals[J]. High Voltage Engineering, 2021, 47(9): 3036-3046.
- [2] 周孝信,陈树勇,鲁宗相,等.能源转型中我国新一代电力

系统的技术特征[J].中国电机工程学报,2018,38(7):1893-1904.

ZHOU Xiaoxin, CHEN Shuyong, LU Zongxiang, et al. Technical characteristics of China's new generation power system in energy transformation [J]. Proceedings of the CSEE, 2018, 38(7): 1893-1904.

- [3] 张智刚,康重庆.碳中和目标下构建新型电力系统的挑战与展望[J].中国电机工程学报,2022,42(8):2806-2819.
ZHANG Zhigang, KANG Chongqing. Challenges and prospects for constructing the new-type power system towards a carbon neutrality future [J]. Proceedings of the CSEE, 2022, 42(8): 2806-2819.
- [4] 汤奕,崔晗,李峰,等.人工智能在电力系统暂态问题中的应用综述[J].中国电机工程学报,2019,39(1):2-13.
TANG Yi, CUI Han, LI Feng, et al. Review on artificial intelligence in power system transient stability analysis [J]. Proceedings of the CSEE, 2019, 39(1): 2-13.
- [5] STOTT B. Power system dynamic response calculations [J]. Proceedings of the IEEE, 1979, 67(2): 219-241.
- [6] FOUAD A A, KRUEMPEL K C, VITTAL V, et al. Transient stability program output analysis [J]. IEEE Power Engineering Review, 1986, PER-6(2): 24-25.
- [7] GLESS G E. Direct method of liapunov applied to transient power system stability [J]. IEEE Transactions on Power Apparatus and Systems, 1966, PAS-85(2): 159-168.
- [8] 张哲,秦博宇,高鑫,等.融合注意力机制和卷积神经网络的电网暂态电压稳定评估及可解释性分析[J].电网技术,2024,48(11):4648-4657.
ZHANG Zhe, QIN Boyu, GAO Xin, et al. Transient voltage stability assessment and interpretability analysis of power grids based on the fusion of attention mechanism and convolutional neural network [J]. Power System Technology, 2024, 48(11): 4648-4657.
- [9] 庄福振,罗平,何清,等.迁移学习研究进展[J].软件学报,2015,26(1):26-39.
ZHUANG Fuzhen, LUO Ping, HE Qing, et al. Survey on transfer learning research [J]. Journal of Software, 2015, 26(1): 26-39.
- [10] 卓振宇,张宁,谢小荣,等.高比例可再生能源电力系统关键技术及发展挑战[J].电力系统自动化,2021,45(9):171-191.
ZHUO Zhenyu, ZHANG Ning, XIE Xiaorong, et al. Key technologies and developing challenges of power system with high proportion of renewable energy [J]. Automation of Electric Power Systems, 2021, 45(9): 171-191.
- [11] 王渝红,何其多,郑宗生,等.基于条件生成对抗网络与迁移学习的暂态电压稳定超前判别[J].电力自动化设备,2025,45(2):159-166.

- WANG Yuhong, HE Qiduo, ZHENG Zongsheng, et al. Lead discrimination of transient voltage stability based on conditional generation adversarial network and transfer learning[J]. Electric Power Automation Equipment, 2025, 45(2):159-166.
- [12] 李晶晶, 孟利超, 张可, 等. 领域自适应研究综述[J]. 计算机工程, 2021, 47(6):1-13.
LI Jingjing, MENG Lichao, ZHANG Ke, et al. Review of studies on domain adaptation[J]. Computer Engineering, 2021, 47(6):1-13.
- [13] HAN H G, MENG Y, WU X L, et al. A transfer learning-based multimodal feature fusion model for bearing fault diagnosis[J]. IEEE Transactions on Instrumentation and Measurement, 2025, 74:3530413.
- [14] LI B Q, WU J Y. Adaptive assessment of power system transient stability based on active transfer learning with deep belief network[J]. IEEE Transactions on Automation Science and Engineering, 2023, 20(2):1047-1058.
- [15] 吴俊勇, 史法顺, 李栎苏, 等. 基于MRSE-CNN的电力系统多任务暂态稳定自适应评估[J]. 电力自动化设备, 2025, 45(2):167-175.
WU Junyong, SHI Fashun, LI Lusu, et al. Multi-task transient stability adaptive assessment of power system based on MRSE-CNN[J]. Electric Power Automation Equipment, 2025, 45(2):167-175.
- [16] 李楠, 张帅, 胡禹先, 等. 一种基于深度自适应网络迁移的暂稳评估模型更新框架[J]. 电力系统保护与控制, 2024, 52(14):25-35.
LI Nan, ZHANG Shuai, HU Yuxian, et al. An updating framework of a model for transient stability assessment based on a deep adaptive network transfer[J]. Power System Protection and Control, 2024, 52(14):25-35.
- [17] ZHANG W, DENG L F, ZHANG L, et al. A survey on negative transfer[J]. IEEE/CAA Journal of Automatica Sinica, 2023, 10(2):305-329.
- [18] 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.
- [19] 王博文, 王龙飞, 董伟, 等. 受端电网暂态失稳场景识别及控制措施优化[J]. 浙江电力, 2023, 42(3):71-78.
WANG Bowen, WANG Longfei, DONG Wei, et al. Recognition of transient instability scenarios of the receiving-end grid and control strategy optimization[J]. Zhejiang Electric Power, 2023, 42(3):71-78.
- [20] 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 two-stage transfer learning[J]. Automation of Electric Power Systems, 2022, 46(17):176-185.
- [21] GOODFELLOW I, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial networks[J]. Communications of the ACM, 2020, 63(11):139-144.
- [22] GANIN Y, USTINOVA E, AJAKAN H, et al. Domain-adversarial training of neural networks[M]//Domain Adaptation in Computer Vision Applications. Cham: Springer International Publishing, 2017:189-209.
- [23] SMOLA A, GRETTON A, SONG L, et al. A Hilbert space embedding for distributions[C]//Algorithmic Learning Theory. Berlin, Heidelberg: Springer, 2007:13-31.
- [24] 王艳新, 闫静, 王建华, 等. 基于域对抗迁移卷积神经网络的小样本GIS绝缘缺陷智能诊断方法[J]. 电工技术学报, 2022, 37(9):2150-2160.
WANG Yanxin, YAN Jing, WANG Jianhua, et al. Intelligent diagnosis for GIS with small samples using a novel adversarial transfer learning in convolutional neural network[J]. Transactions of China Electrotechnical Society, 2022, 37(9):2150-2160.
- [25] 薛安成, 周健, 刘瑞煌, 等. 采用多二元表判据的实用暂态电压稳定裕度指标研究[J]. 中国电机工程学报, 2018, 38(14):4117-4125.
XUE Ancheng, ZHOU Jian, LIU Ruihuang, et al. Study on practical transient voltage stability margin index using multi-binary table criterion[J]. Proceedings of the CSEE, 2018, 38(14):4117-4125.

收稿日期: 2025-05-20; 修回日期: 2025-08-01

作者简介:

郑瀚林(2001), 男, 工学硕士, 主要从事机器学习在电力系统中应用方面的研究工作。

王怀远(1987), 男, 博士, 副教授, 主要从事电力系统运行与控制方面的研究工作。(通信作者)

(本文编辑: 张瑞敏)