

DOI: 10.19783/j.cnki.pspc.240029

一种基于深度自适应网络迁移的暂稳评估模型更新框架

李楠^{1,2}, 张帅², 胡禹先³, 隋想⁴

(1. 现代电力系统仿真控制与绿色电能新技术教育部重点实验室(东北电力大学), 吉林 吉林 132012; 2. 东北电力大学电气工程学院, 吉林 吉林 132012; 3. 国家电网吉林省电力有限公司白城供电公司, 吉林 白城 137000; 4. 南京南瑞继保电气有限公司, 江苏 南京 210000)

摘要: 为解决电力系统的运行方式或拓扑结构变化后暂稳评估模型的适应性问题, 常规的特征迁移学习方法主要侧重于拉近源域与目标域数据集间的条件分布或边缘分布的距离, 却不能定量的评价这两种分布对于不同域之间的贡献, 导致模型迁移性能不理想。针对该问题, 引入 SENet 注意力机制和动态分布自适应算法, 构建了基于 SE-DDAN 迁移的深度自适应网络暂稳评估模型更新框架, 从特征提取和不同域间分布权重的动态调整两个层面进行改进, 进一步提升了评估模型的迁移性能和自适应性。在 IEEE 39 和 IEEE 140 节点系统上进行测试, 仿真结果表明所提模型在更新后的评估准确性、适应性和迁移性能方面有一定的优势。

关键词: 电力系统; 评估; 迁移学习; 注意力机制; 动态自适应分布

An updating framework of a model for transient stability assessment based on a deep adaptive network transfer

LI Nan^{1,2}, ZHANG Shuai², HU Yuxian³, SUI Xiang⁴

(1. Key Laboratory of Modern Power System Simulation and Control & Renewable Energy Technology, Ministry of Education (Northeast Electric Power University), Jilin 132012, China; 2. School of Electrical Engineering, Northeast Electric Power University, Jilin 132012, China; 3. Baicheng Power Supply Company, State Grid Jilin Electric Power Co., Ltd., Baicheng 137000, China; 4. NR Electric Co., Ltd., Nanjing 210000, China)

Abstract: To solve the adaptability problem of transient stability assessment models after the changes in the operation or topology of power systems, the conventional feature transfer learning methods mainly focus on bringing the conditional or marginal distributions between the source and target domain datasets closer together, but fail to quantitatively evaluate the contribution of the two distributions to different domains, resulting in unsatisfactory model transfer performance. To address this problem, SENet attention mechanism and dynamic distribution adaptive algorithm are introduced, and a deep adaptive network transient stability assessment model update framework based on SE-DDAN transfer is constructed, which is improved from two aspects, namely, feature extraction and dynamic adjustment of distribution weights between different domains, to further enhance the transfer performance and adaptability of the assessment model. The model is tested on IEEE39-bus and IEEE140-bus systems and the simulation results that the proposed model has advantages in assessment accuracy, adaptability and transfer performance after updating.

This work is supported by the National Natural Science Foundation of China (No. 61973072).

Key words: power system; assessment; transfer learning; attention mechanism; dynamic adaptive distribution

0 引言

随着可再生能源的比例不断提高, 越来越多的新型负荷接入电网^[1-3], 导致电力系统的运行方式和拓扑结构面临着更复杂的动态变化。系统一旦失稳,

将会造成灾难性事件, 例如设备损坏、大规模停电等^[4-6]。将人工智能算法用于电力系统态势分析中时, 暂态稳定评估(transient stability assessment, TSA)模型通常是基于离线的源域数据训练获得的, 在线运行时系统运行方式或拓扑结构变化, 会导致目标域的数据分布发生变化, 使评估模型的性能下降, 严重时甚至失效。因此, 针对复杂的电网结构, TSA

基金项目: 国家自然科学基金项目资助(61973072)

模型更新方法的研究对于电力系统安全稳定运行具有重要意义。

在基于人工智能的 TSA 方法中, 诸如支持向量机(support vector machine, SVM)^[7]、决策树(decision tree, DT)^[8]和随机森林(random forests, RF)^[9]等机器学习方法, 对海量电力数据的挖掘能力^[10]有限, 在处理高维度的复杂数据时表现较差, 由其构造的暂态稳定评估模型在性能上表现一般。而深度学习在处理多类因素共同影响、机理不清晰的复杂问题时具有显著的优势^[11-13], 可在海量数据中挖掘深层次复杂的关联信息, 在 TSA 中取得了颇有成效的研究成果。文献[14]提出了一种基于广义回归神经网络的暂态稳定评估模型, 利用贝叶斯决策算法对输入特征进行分类, 该模型具有较高的准确率和较低的误判率。文献[15]利用图卷积网络对电力系统特征进行挖掘, 实现了快速动态安全的暂态稳定评估。文献[16]提出基于深度置信网络(deep belief network, DBN)的暂态稳定评估模型, 利用深层网络的特征提取能力和大量无标注样本, 提高了评估准确率。文献[17]提出了一种级联卷积神经网络的快速暂态稳定评估模型, 可以自动提取特征, 预测稳定概率, 该模型在较短的时间内取得了较好的评估效果。文献[18]通过引入代价敏感函数, 将长短期记忆网络(long short-term memory, LSTM)与改进的 Adaboost 相结合, 解决了样本不平衡的问题, 提高了评估模型的综合性能。

上述基于深度学习方法构建的模型虽取得了较好的评估性能, 但由于电力系统具有较强的时变性, 离线训练获得的评估模型在线运行时, 遭遇到不同于训练时的场景, 该实测数据分布与训练数据分布就有可能不一致, 将导致电力系统暂态稳定评估模型的性能下降甚至失效, 很难满足在线应用的需求。因此, 暂态稳定评估模型的构建均需考虑模型的普适性及更新问题。现有模型更新方法主要分为三类。1) 将源域训练模型迁移到目标域, 利用微调技术完成更新。文献[19]通过变步长和二分法生成最小均衡样本集, 结合微调技术实现模型的更新。文献[20]针对电力系统拓扑变化问题, 将原拓扑训练的模型通过微调全连接层进行模型更新, 满足了在线应用的实时性需求。文献[21]针对单一模型存在的问题, 将 DBN、LSTM、卷积神经网络(convolutional neural network, CNN)进行融合提出了一种自适应评估方法, 利用少量目标域样本微调模型, 大大地缩短了模型的更新训练时间。2) 利用短时间仿真生成无标注样本进行更新。文献[22]提出一种基于 DBN 的主动迁移学习方法, 利用主动学习筛选出信息量丰富

的样本进行标注, 减少了迁移更新的时间。文献[23]提出了一种基于数据继承思想的暂态稳定评估方法, 实现了小样本条件下的模型更新。3) 利用领域自适应方法减少源域与目标域分布差异, 从而帮助模型完成更新。文献[24]基于深度子领域自适应方法提出一种两阶段 TSA 框架, 提高了模型的评估性能, 减少了模型更新时间。前两类方法虽然解决了模型更新问题, 但模型存在过拟合风险并且无法很好处理源域和目标域之间的分布差异, 而第三类方法通过领域自适应可以减少数据分布差异, 降低过拟合风险并且不需要大量标记数据, 提高了模型泛化能力和评估性能。但在减少源域和目标域数据的数据分布差异中, 未考虑条件分布和边缘分布的权重影响。而在实际情况中条件分布和边缘分布对域散度的贡献是不同的, 忽视这一问题可能会影响迁移效果, 导致评估性能下降。

基于此, 本文引入动态分布自适应(dynamic distribution adaptation, DDA)算法^[25], 对迁移学习中边缘分布和条件分布的权重进行动态、定量的自适应调整。在此基础上设计了动态自适应分布网络, 采用改进的 CNN 从输入量中提取特征, 同时使用 DDA 算法进行领域自适应, 通过最大均值差异(maximum mean discrepancy, MMD)计算域间散度来动态学习分布权重, 最终得到一个域不变的分器。在 IEEE 39 和 IEEE 140 节点系统上进行仿真验证, 算例表明本文所提模型具有良好的分类评估性能, 并且可以显著提高迁移性能。

1 算法原理

1.1 基于 SE-CNN 的特征提取

常规 CNN 通常利用具有不同感受野的卷积运算提取各层的局部信息, 将空间和特征通道维度上的信息进行聚合来构造信息特征。然而, CNN 在进行特征提取时并未考虑通道之间的关联性, 这就意味着网络无法捕捉不同通道间的复杂关系, 限制了网络的表达能力和性能。为解决这一问题, 在 CNN 的通道维度上引入注意力机制, 提出了一种新的架构单元, 即增加了挤压和激励网络(squeeze-and-excitation networks, SENet)^[26], 显式建模卷积特征通道之间动态、非线性的相互依赖关系。同时, 采用了一种全新的“特征重标定”策略, 通过自动学习 CNN 的通道信息, 获取特征图中每个通道的重要程度, 并根据重要程度赋予其不同的权重值, 自适应地重新校准通道特征响应, 从而达到进一步提升 CNN 性能的目的。

SENet 模块的结构如图 1 所示。

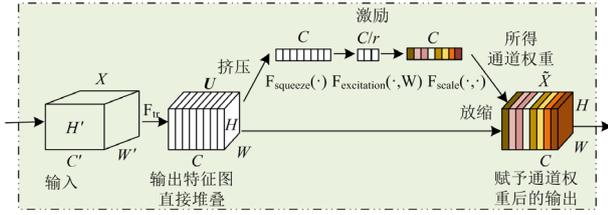


图1 SENet 结构示意图

Fig. 1 SENet structure diagram

本文将 SENet 插入 CNN 中即完成基于 SE-CNN 的暂态稳定评估模型的构建, 无需重新设计网络架构和调整超参数并且不会显著增加模型的复杂性和计算负担。SE-CNN 网络模型结构主要由输入层、3 层卷积层、3 层池化层、2 个 SE 模块、3 个全连接层和输出层构成, 如图 2 所示。

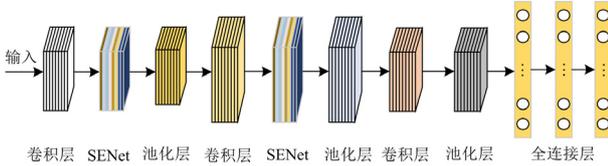


图2 SE-CNN 网络结构图

Fig. 2 SE-CNN network structure diagram

在评估模型中引入 SE 注意力机制主要基于以下原因:

- 1) 有助于模型更好地捕捉电力特征间的动态关系, 提高模型对重要特征的敏感性;
- 2) 有助于实现模型在不同电力系统场景或工况之间的迁移学习, 在不同场景或工况下动态地调整对不同通道特征的关注意度, 使模型更具泛化能力。

1.2 动态分布自适应

在迁移学习中, 基于特征的迁移是对数据进行自适应变换, 拉近目标域与源域数据分布的距离, 实现域间的特征对齐, 主要方法包括边缘分布自适应(marginal distribution adaptation, MDA)、条件分布自适应(conditional distribution adaptation, CDA)及联

合分布自适应(joint distribution adaptation, JDA)。3 种方法中, JDA 综合考虑了边缘分布及条件分布的依赖关系, 能对源域和目标域数据之间的关系进行全面建模。DDA 是在 JDA 的基础上对分布权重进行了改进, 具体原理如下所述。

1) DDA 原理

本节用 Ω_s 表示源域, Ω_t 表示目标域, 为衡量两个域间数据分布之间的差异, 通常使用最大均值差异 MMD 来计算域间的分布散度。其中, 边缘分布距离和条件分布距离的计算分别如式(1)、式(2)所示。

$$D_f(P_s, P_t) = \|E[f(x_s)] - E[f(x_t)]\|_H^2 \quad (1)$$

$$D_f^{(a)}(Q_s, Q_t) = \|E[f(x_s^{(a)})] - E[f(x_t^{(a)})]\|_H^2 \quad (2)$$

式中: $D_f(P_s, P_t)$ 为边缘分布距离; $D_f^{(a)}(Q_s, Q_t)$ 为 a 类指标的条件分布距离, $a \in \{1, \dots, A\}$; $x_s \in \Omega_s$, $x_t \in \Omega_t$ 。

域间的 JDA 域散度计算如式(3)所示。

$$\overline{D_f}(\Omega_s, \Omega_t) = D_f(P_s, P_t) + \sum_{a=1}^A D_f^{(a)}(Q_s, Q_t) \quad (3)$$

在式(3)中, JDA 给予边缘分布距离和条件分布距离相同的权重。但当两个领域的的数据整体不相似时, 边缘分布更重要, 则 $D_f(P_s, P_t)$ 在式(3)中应被赋予更大的权重; 而当两个领域的的数据整体结构相似, 但每个类有差异时, 条件分布更重要, 则 $D_f^{(a)}(Q_s, Q_t)$ 在式(3)中应被赋予更大的权重。

在实际的电力数据中, 电力系统运行场景及拓扑结构的变化会导致电力数据特征分布的不同, 下面以电力系统拓扑结构改变为例, 说明不同域间数据分布的差异性。针对 IEEE 39 和 IEEE 140 节点系统分别给出拓扑结构未改变的源域及两种拓扑结构改变的目标域的特征分布可视化图(此处采用 t-SNE^[27]将 SE-CNN 提取的特征进行可视化分析), 如图 3 和图 4 所示(图中 S 、 A 、 E 和 Y 、 Y_1 、 Y_2 为不同域下的数据集, 如附录 A 表 A1 所示)。

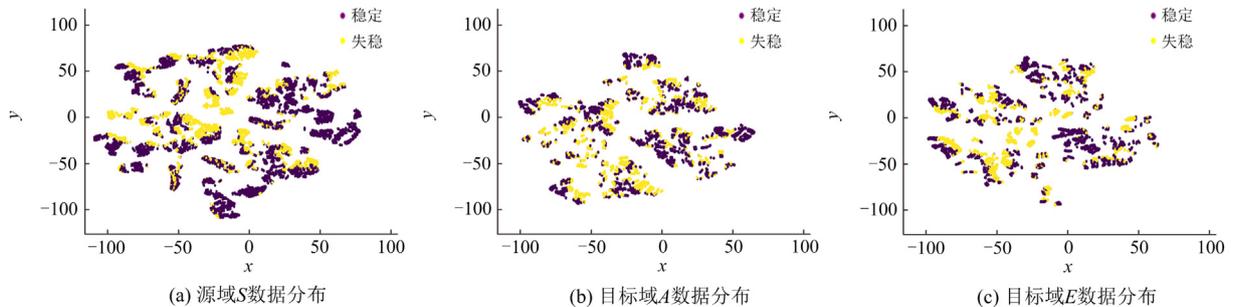


图3 IEEE 39 节点系统源域、目标域数据分布

Fig. 3 IEEE 39 node system source domain and target domain data distribution

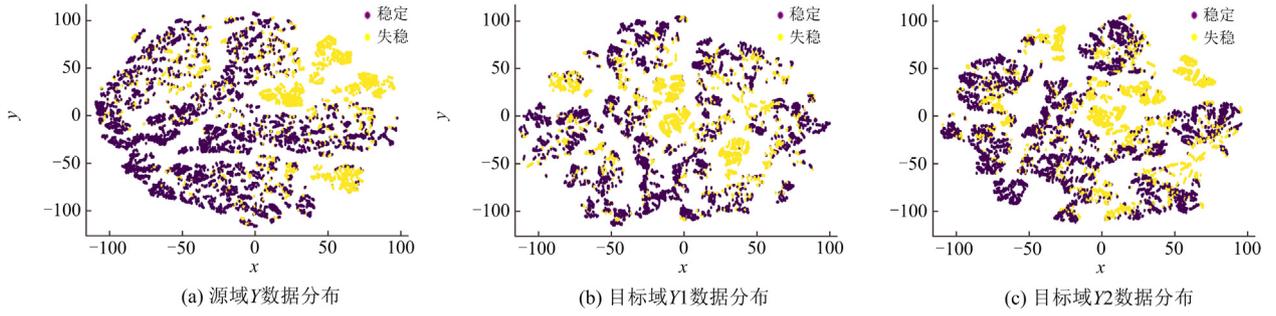


图 4 IEEE 140 节点系统源域、目标域数据分布

Fig. 4 IEEE 140 node system source domain and target domain data distribution

由图 3 和图 4 可知：从数据样本层面来看，首先源域和目标域中的稳定与失稳样本数量不同，其次 SENet 所提取的特征在空间分布上具有差异性；从分布的结构层面来看，源域与目标域中的稳定和失稳样本既有相似的边界，也有不同的重叠交叉部分，说明电力系统在不同的运行状态下，数据特征的空间分布和条件分布会发生较大的变化，所以应当被赋予其不同的权重。

为体现边缘分布与条件分布在域散度中的贡献程度，提出了一种基于动态分布自适应的迁移学习方法，通过引入自适应因子来动态地调整两个分布的权重。动态分布的域散度 \overline{D}_f 定义为

$$\overline{D}_f(\Omega_s, \Omega_t) = (1 - \mu)D_f(P_s, P_t) + \mu \sum_{a=1}^A D_f^{(a)}(Q_s, Q_t) \quad (4)$$

式中， $\mu \in [0, 1]$ 为自适应因子。当 $\mu \rightarrow 0$ 时，表示源域与目标域数据存在较大差异性，此时边缘分布更为重要；当 $\mu = 0.5$ 时，表示两分布具有同等的重要性；当 $\mu \rightarrow 1$ 时，表示源域与目标域数据有较高相似性，此时条件分布更为重要。

2) 自适应因子 μ 的定量估计与分析

DDA 的自适应因子 μ 通常与源域和目标域间的分布差异以及线性分类器的性能有关。在对 μ 进行定量估计时，不同域间的分布差异使用 A-distance 作为度量准则。采用线性分类器 h 对源域 Ω_s 和目标域 Ω_t 进行分类判别， $\varepsilon(h)$ 表征两个域间的判别误差。A-distance 的定义如式(5)所示。

$$d(\Omega_s, \Omega_t) = 2(1 - 2\varepsilon(h)) \quad (5)$$

利用式(5)可以直接计算边缘分布的 A-distance，用 d_M 来表示。对于类别 a 的条件分布的 A-distance，可由式(6)计算得出。

$$d_a = d(\Omega_s^{(a)}, \Omega_t^{(a)}) \quad (6)$$

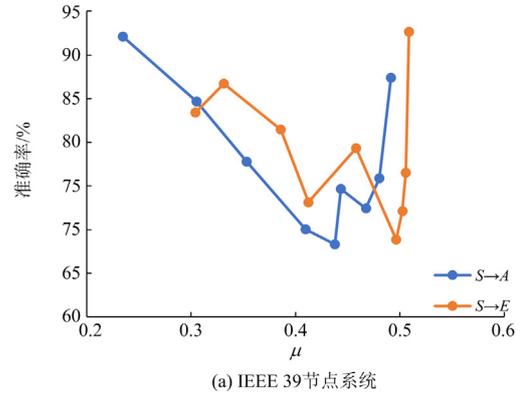
式中， $\Omega_s^{(a)}$ 和 $\Omega_t^{(a)}$ 分别表示来自源域和目标域的第 a 类指标的样本。

域散度是由边缘分布和条件分布共同作用的，可用 $d_M + \sum_{a=1}^A d_a$ 表示，其中 $\sum_{a=1}^A d_a$ 为所有类的条件分布距离。则 μ 可以由式(7)估计获得。

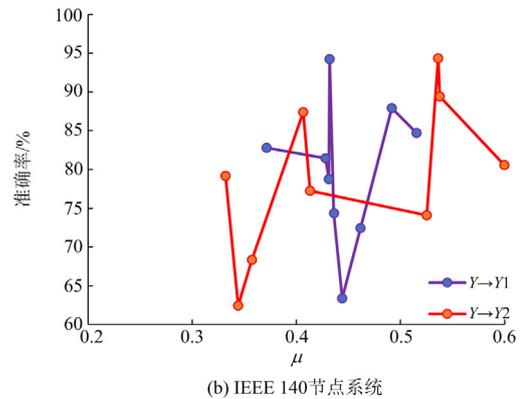
$$\mu = 1 - \frac{d_M}{d_M + \sum_{a=1}^A d_a} \quad (7)$$

由于特征的动态和渐近变化性，此估计需要在动态分布自适应的每一轮迭代中给出。

本文在 IEEE 39 和 IEEE 140 节点系统中随机设置参数 μ 进行迭代训练，得到的评估结果如图 5 所示。



(a) IEEE 39 节点系统



(b) IEEE 140 节点系统

图 5 不同 μ 值迁移下的模型性能

Fig. 5 Model performance under different μ value transfer

由图5可以看出, 评估模型的准确率随着 μ 值的变化而变化, 在不同电力系统运行场景下, μ 的最优值并不相同, 所以有必要根据不同的运行工况来自适应动态地调整边缘分布和条件分布的权重, 使评估模型性能达到最优。

2 基于最大均值差异的 SE-DDAN

2.1 最大均值差异

最大均值差异 MMD 是迁移学习中使用频率较高的度量之一。假设 $X^s \in \Omega_s$ 、 $X^t \in \Omega_t$ 为不同域上的样本集, 其数据分布分别用 P 和 Q 表示, P 、 Q 之间的 MMD 距离定义为

$$MMD(H_k, P, Q) = \sup_{\|f\|_{H_k} \leq 1} E_{X^s} [f(X^s)] - E_{X^t} [f(X^t)] \quad (8)$$

式中: H_k 是由 Mercer 核 $K(\cdot, \cdot)$ 定义的再生核希尔伯特空间(reproducing kernel Hilbert space, RKHS); $\|f\|_{H_k} \leq 1$ 为其单位范数球; $E[\cdot]$ 为嵌入样本的均值; $f(\cdot)$ 为数据到 RKHS 的映射函数。

为简化计算, 对样本 X^s 和 X^t , 利用经验期望代替统计期望得到的 MMD 有偏经验估计, 如式(9)所示。

$$MMD(H_k, P, Q) = \sup_{\|f\|_{H_k} \leq 1} \left(\frac{1}{m} \sum_{i=1}^m f(x_i^s) - \frac{1}{n} \sum_{i=1}^n f(x_i^t) \right) \quad (9)$$

式中: m 、 n 分别为 P 和 Q 的样本数; x_i^s 为 X^s 中第 i 个样本; x_i^t 为 X^t 中第 i 个样本。

为简化计算, 假设 $m = n$, 提出具有线性计算复杂度的 MMD 无偏估计, 如式(10)所示。

$$MMD_1^2(s, t) = \frac{2}{m} \sum_{i=1}^{m/2} h(z_i) \quad (10)$$

式中, h 是定义在四元组 $z_i = (x_{2i-1}^s, x_{2i}^s, x_{2j-1}^t, x_{2j}^t)$ 上的算子, 如式(11)所示。

$$h(z_i) = k(x_{2i-1}^s, x_{2i}^s) + k(x_{2j-1}^t, x_{2j}^t) - k(x_{2i-1}^s, x_{2j}^t) - k(x_{2i}^s, x_{2j-1}^t) \quad (11)$$

式中, k 为核函数, 用来度量样本点之间的相似性。

2.2 SE-DDAN 结构设计

将分类评估模型应用于电力系统的暂态分析时, 通常将离线训练时的数据集当作源域, 在线应用时的数据集作为目标域, 由于可再生能源的接入及电力系统工况的改变, 两个域间的分布差异增大问题凸显。因此, 动态分布自适应网络设计思路为: 1) 在原有动态自适应网络的基础上改进了特征提取器, 采用 SE-CNN 使其更关注于不同通道间特征

的相互依赖关系, 有助于提高 DDA 中数据分布对齐的有效性; 2) 采用具有线性计算复杂度的无偏估计 MMD 和随机梯度下降算法, 降低了计算开销, 提高模型对于不同数据分布的适应性。网络架构如图6所示。

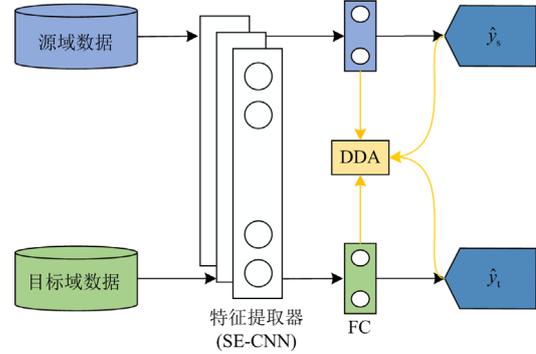


图6 SE-DDAN 网络架构图

Fig. 6 SE-DDAN network architecture diagram

SE-DDAN 具体学习过程如表1所示。在模型训练时, 参数的梯度的计算如式(12)所示。

$$\Delta \Theta = \frac{\partial J(\cdot, \cdot)}{\partial \Theta} + \lambda \frac{\partial \overline{D_f}(\cdot, \cdot)}{\partial \Theta} + \rho \frac{\partial R_f(\cdot, \cdot)}{\partial \Theta} \quad (12)$$

式中: $J(\cdot, \cdot)$ 为交叉熵损失函数; Θ 为包含神经网络的权值和偏置参数, $\Theta = \{w, b\}$; $R_f(\cdot, \cdot)$ 为拉普拉斯正则化项; λ 、 ρ 为正则化参数。

采用动态分布自适应方法, 其学习目标函数 f 可以表示为

$$f = \min_{\Theta} \sum_{i=1}^n J(f(x_i^s), y_i^s) + \lambda \overline{D_f}(\Omega_s, \Omega_t) + \rho R_f(\Omega_s, \Omega_t) \quad (13)$$

表1 SE-DDAN 学习过程

Table 1 SE-DDAN learning process

SE-DDAN: 动态分布自适应网络	
输入:	源域数据 (x^s, y^s) , 目标域数据 x^t , 正则化参数 λ 和 ρ
输出:	分类器 f
(1)	从源域和目标域采样一小批数据;
(2)	将小批量数据提供给网络, 并获得 Ω_t 的伪标签;
(3)	根据式(12)计算小批量梯度, 更新参数 (ω, b) ;
(4)	在每个 epoch 后, 使用式(7)计算 μ , 并计算损失;
(5)	重复上述步骤直到收敛, 返回分类器 f 。

3 基于 SE-DDAN 迁移的暂稳评估模型

3.1 模型的评估流程

模型的输入特征对其性能有着重大影响, 本文将故障切除后的母线电压幅值作为轨迹簇, 根据轨迹簇的几何属性定义了 30 个维度不变的输入特征

集, 详细构建方法参考文献[28]。稳定状态依据暂态稳定指数(TSI)来判断是否失稳, 0 来表示稳定, 1 表示失稳。

$$\delta_{TSI} = \frac{360 - |\Delta\delta_{\max}|}{360 + |\Delta\delta_{\max}|} \quad (14)$$

式中, $|\Delta\delta_{\max}|$ 为任意 2 台发电机之间的功角差最大

值的绝对值。当 $\delta_{TSI} > 0$ 时, 样本判定为稳定, $\delta_{TSI} < 0$ 则判定为失稳。

基于 SE-DDAN 的 TSA 主要包括三个阶段——离线训练、在线阶段、模型更新。模型的暂态稳定评估流程图如图 7 所示。

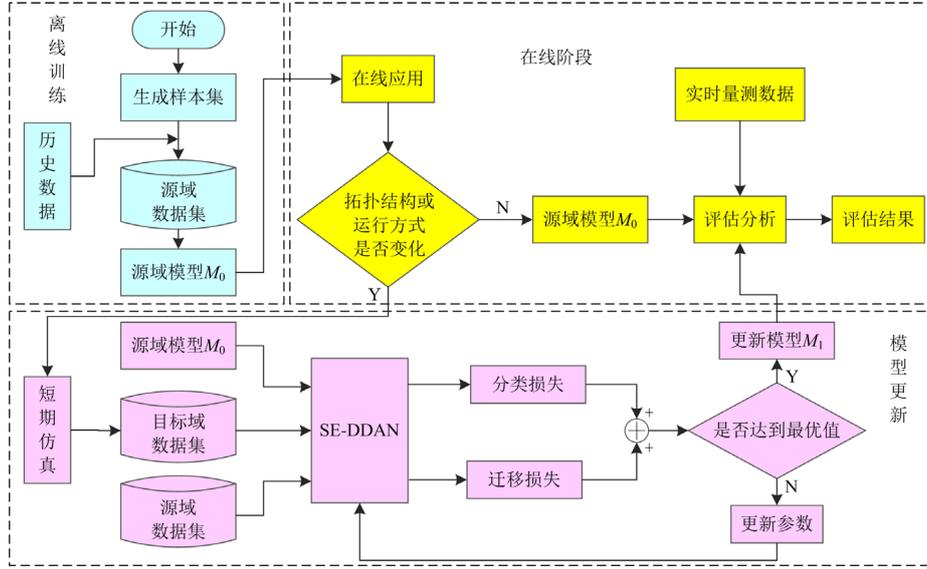


图 7 TSA 整体评估流程图

Fig. 7 TSA overall evaluation flow chart

1) 离线训练: 由时域仿真法生成数据, 提取 30 个维度不变的轨迹簇特征, 并和历史数据构成源域数据集, 对其进行最大最小归一化处理, 按照一定的比例划分训练集和测试集训练, 得到源域模型 M_0 。

2) 在线阶段: 当电网正常运行时, 通过读取相量测量单元(phasor measurement unit, PMU)获得实时量测数据, 利用离线训练得到的评估模型进行判稳, 输出预测结果。评估模型在线运行时, 基于以下两种判别是否需要模型更新: (1) 根据系统负荷的周期性变化规律, 在设定好的时间间隔内定期的更新; (2) 监测到系统的运行方式或拓扑结构发生变化时, 立即进行更新。

3) 模型更新: 首先针对系统的变化通过短期仿真快速生成少量样本, 然后利用源域模型、源域数据集和目标域数据集训练 SE-DDAN, 通过动态分布自适应方法动态调整边缘分布和条件分布的权重, 减小源域和目标域的数据分布差异 MMD 值, 当分类损失和迁移损失相加达到最优时, 得到适用于当前工况的更新后的模型 M_1 。

3.2 评估指标

为了更好地评判分类模型性能, 本文采用的评

估指标包括准确率 (P_{Acc})、稳定样本精确率 (T_{pr})、失稳样本精确率 (T_{ur}) 及综合指标 (G_{mean}), 其计算公式分别如式(15)一式(18)所示。

$$P_{Acc} = \frac{T_s + T_{us}}{T_s + T_{us} + F_{us} + F_s} \times 100\% \quad (15)$$

$$T_{pr} = \frac{T_s}{T_s + F_{us}} \times 100\% \quad (16)$$

$$T_{ur} = \frac{T_{us}}{F_s + T_{us}} \times 100\% \quad (17)$$

$$G_{mean} = \sqrt{T_{pr} T_{ur}} \times 100\% \quad (18)$$

式中: T_s 和 T_{us} 分别为稳定和失稳样本预测正确的数目; F_{us} 为稳定被错误分类成失稳样本的数量; F_s 为失稳被漏判成稳定样本的数量。判别混淆矩阵如表 2 所示。

表 2 混淆矩阵

Table 2 Confusion matrix

系统实际状态	判别结果	
	稳定	失稳
稳定	T_s	F_{us}
失稳	F_s	T_{us}

4 算例分析

为了验证所提框架的有效性, 本文在 IEEE 39 和 IEEE 140 节点系统上进行仿真验证。电力系统仿真软件为 PSD-BPA, 编程语言为 Python。计算机配置为 AMD R7-5800 CPU/RTX 3060Ti/16 GB RAM。

4.1 样本生成

IEEE 39 节点系统包含 10 台发电机和 39 条母线。算例考虑负荷水平的范围为 80%~120%, 负荷增加步长为 5%, 共有 9 种负荷情况。故障类型为三相短路故障。故障点设置在交流线路的 0%、10%、20%、...、90%处, 在发生故障 0.1 s、0.15 s、0.18 s、0.2 s 后故障切除, 仿真时长为 20 s, 仿真步长为 0.01 s。系统一共生成仿真样本 12 240 个, 其中稳定样本 7986 个, 失稳样本 4254 个。IEEE 140 节点系统故障点位置分别为 20%、50%、80%, 其余条件与 IEEE 39 节点系统相同, 生成 22 140 个样本, 稳定样本 15 201 个, 失稳样本 6939 个。将 IEEE 39 节点系统和 IEEE 140 节点系统作为源系统, 目标系统在源系统基础上随机停运某线路。数据集的设置如附录 A 表 A1 所示, 其中 S 和 Y 为源域数据集, A 至 F 和 $Y1$ 、 $Y2$ 、 $Y3$ 为目标域数据集。将各数据集按 4:1 划分训练集和测试集。

4.2 模型性能对比

为验证 SE-CNN 评估模型的性能, 将其与 CNN、DT、RF、SVM、极限梯度提升机(extreme gradient boosting, XGB)在源域数据集 S 和 Y 上进行对比, 将对比结果分别列于表 3、表 4 中。其中, DT 采用 CART 算法, 最大深度为 7; RF 和 XGB 基分类器数量为 50, 最大深度为 5, 学习率为 0.1; SVM 使用径向基函数; CNN 除 SENet 模块外采用和 SE-CNN 相同的结构, 如附录 A 图 A1 所示。

由表 3、表 4 可知, SE-CNN 与其他评估模型相比, P_{Acc} 和 G_{mean} 有着明显的优势, 在两套系统上都有着较好的评估性能。

表 3 IEEE 39 节点系统中不同模型性能对比

Table 3 Performance comparison of different models in IEEE39-bus system

模型	P_{Acc}	T_{pr}	T_{ur}	G_{mean}
DT	95.58	95.78	95.19	95.48
RF	96.85	96.13	97.09	96.60
SVM	96.36	96.80	95.54	96.17
XGBoost	97.47	98.11	97.40	97.75
CNN	98.39	98.62	97.75	98.27
SE-CNN	98.81	98.75	98.91	98.83

表 4 IEEE 140 节点系统中不同模型性能对比

Table 4 Performance comparison of different models in IEEE140-bus system

模型	$P_{Acc}/\%$	$T_{pr}/\%$	$T_{ur}/\%$	$G_{mean}/\%$
DT	95.98	96.21	95.44	95.82
RF	97.11	96.96	97.45	97.20
SVM	96.34	96.26	96.53	96.39
XGBoost	97.90	97.88	97.94	97.91
CNN	98.67	98.98	97.96	98.47
SE-CNN	98.85	99.40	97.78	98.59

为对比 SE-CNN 与其他模型在面对不同拓扑结构时的泛化能力和评估性能, 分别在两套系统的不同目标域数据集上测试各个源域模型。重复进行 20 次实验, 取均值作为最终结果, 如图 8 所示。SE-CNN 所覆盖的区域面积最大, 说明其在不同目标域上的性能表现也均优于其他对比模型。相比于源域数据集上的评估性能, T_{ur} 下降幅度较大, T_{pr} 在一定程度上有所下降, 这是因为源域中稳定样本数目占比较大, 模型对该类样本学习较为充分, 并且目标域中失稳与稳定的样本数量相对于源域发生变化, 导致整体类别分布不同, 模型将失稳样本误判为稳定样本。

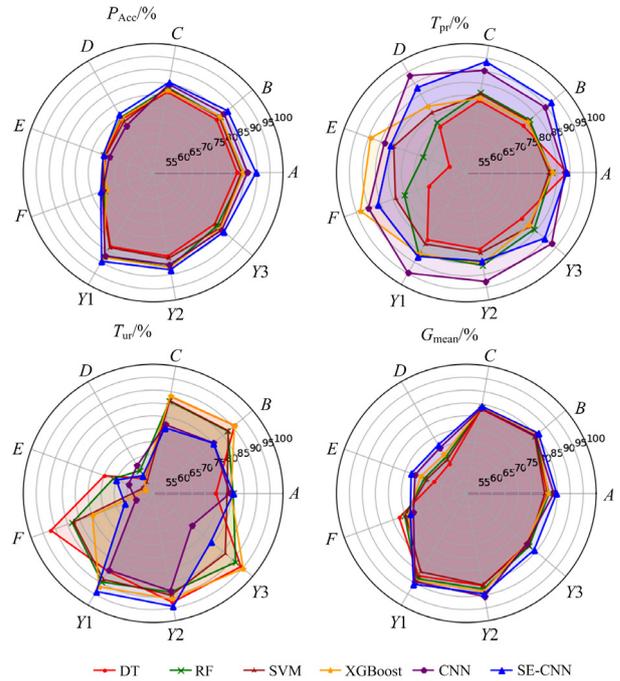


图 8 不同模型在目标域上的性能对比

Fig. 8 Performance comparison of different models in target domain

4.3 SENet 的性能验证及输出可视化

为了进一步验证 SENet 对模型通道的作用, 并

且排除偶然性, 将 SE-CNN 和 CNN 在 IEEE 39 和 IEEE 140 节点系统上分别进行 20 次重复实验, 将得到的准确率分别依次记录下来并绘制成箱型图, 如图 9 所示。从图中可以看出, SE-CNN 的箱子整体要高于 CNN, 并且箱子高度起伏不大, 说明 SE-CNN 可以提升模型分类性能并且比 CNN 稳定。因此, 在后续迁移过程中, 采用 SE-CNN 作为特征提取器。

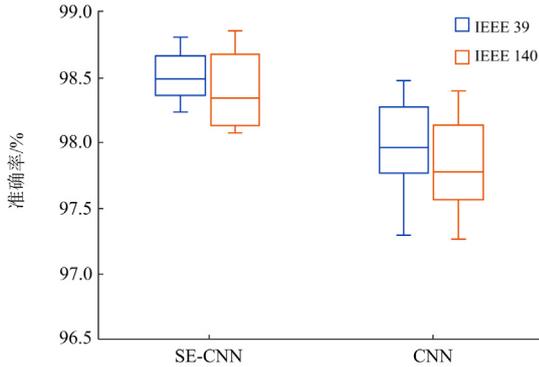


图 9 不同系统下 SE-CNN 与 CNN 准确率箱型示意图
Fig. 9 Box diagram of SE-CNN and CNN accuracy under different systems

为了更加直观地说明 SENet 模块通过建模卷积特征通道之间的关系, 自适应地获得每个通道的重要程度并赋予其不同的权重来提升模型的性能, 从而对 SENet 模块的输出进行可视化。

将划分好的测试集样本依次输入到 SE-CNN 中, 设置迭代次数为 300, 在训练开始时和训练结束后分别记录每个测试集样本经过 SENet 模块输出的通道权重值, 将保存的所有通道权重值进行平均, 得到平均通道权重, 用来表示每个通道的平均重要程度。将平均通道权重绘制成热力图, 如图 10 所示, 图中每个方块的颜色对应着不同通道及其输出权重的大小。

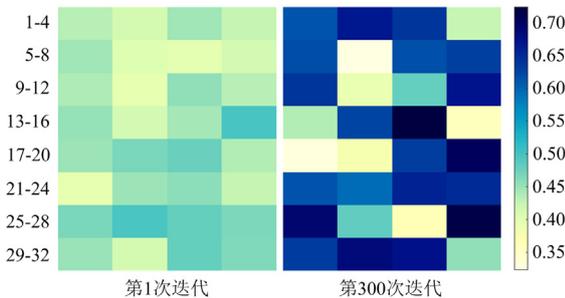


图 10 SENet 输出通道权重热力图
Fig. 10 SENet output channel weight heat map

从图 10 可以看出, 在第 1 次迭代时各通道权重差异较小, 在最后一次迭代后, 通道权重相对于训

练开始时发生了较大的变化, 说明 SENet 模块对各通道赋予了不同的权重, 提升有用通道所占权重的同时抑制对当前任务作用不大的通道, 进一步验证了 SENet 可以自适应学习特征通道的相对重要性。

4.4 PMU 缺失测试

在实际应用中, 由于传感器或网络发生故障, 会导致 PMU 采集到的数据所含有的信息不完整, 此时评估模型无法对缺失的母线电压数据进行有效评估, 进而影响系统的稳定性和可靠性。但轨迹簇特征的维度不会随之改变, 模型仍能继续工作。本文通过在 IEEE 39 和 IEEE 140 节点系统上模拟 PMU 采集信息缺失情况对 SE-CNN 进行测试来验证轨迹簇特征的鲁棒性, 结果如表 5 所示。

表 5 PMU 缺失的性能评估

Table 5 Performance evaluation of missing PMU

缺失母线	IEEE 39 节点系统			
	P_{Acc}	T_{pr}	T_{ur}	G_{mean}
母线 2	98.52	98.50	98.55	98.52
母线 14	98.77	98.87	98.56	98.71
母线 16	98.48	98.25	98.92	98.58
母线 2 和 14	98.64	98.75	98.44	98.59
母线 2 和 16	98.48	98.25	98.92	98.58
母线 14 和 16	98.48	98.25	98.91	98.58
母线 2、14、16	98.27	98.12	98.56	98.34
缺失母线	IEEE 140 节点系统			
	P_{Acc}	T_{pr}	T_{ur}	G_{mean}
母线 53	98.31	99.21	96.31	97.75
母线 54	98.30	99.24	96.15	97.68
母线 104	98.35	99.27	96.22	97.73
母线 53 和 54	98.17	99.24	95.69	97.45
母线 53 和 104	98.19	99.24	95.81	97.51
母线 54 和 104	98.31	99.37	95.83	97.58
母线 53、54、104	98.21	99.40	95.48	97.42

由表 5 可见, 在部分母线信息缺失的情况下, 模型仍然有较好的评估性能。在 IEEE 39 节点系统中, 即使缺失了 3 条母线信息, 评估准确率仍可达到 98.27%。当系统规模扩大为 IEEE 140 节点系统时, 准确率仍然在 98% 以上, 说明借助轨迹簇维度不变这一特性可以很好的应对信息缺失, 有较好的鲁棒性。

4.5 SE-DDAN 在不同目标域下的性能测试

为了验证 SE-DDAN 的迁移性能, 通过不同的数据集对源域模型 SE-CNN 进行迁移。选择不同的深度迁移学习方法进行对比: 深层域混淆网络(deep domain confusion, DDC)、深度适配网络(deep adaptation network, DAN)、领域对抗神经网络(domain adversarial neural network, DANN)。DDC、DAN 均采用和 SE-

DDAN 一样的结构。DDC 在分类器前一层嵌入 MMD; DAN 在 FC1 至 FC3 中嵌入多核 MMD;

DANN 的结构见附录 A 图 A2 所示。重复 20 次实验得到的均值如表 6 所示。

表 6 各模型在不同数据集下的性能对比

Table 6 Performance comparison of various models in different databases

迁移情况	SE-CNN		DDC		DAN		DANN		SE-DDAN	
	P_{Acc}	G_{mean}								
$S \rightarrow A$	85.59	84.78	89.33	89.77	88.12	87.65	86.41	89.59	90.96	92.24
$S \rightarrow B$	86.65	86.25	87.65	87.56	89.65	90.21	89.77	85.72	90.53	89.18
$S \rightarrow C$	83.53	84.52	84.56	83.48	82.28	86.77	85.36	89.23	89.35	91.22
$S \rightarrow D$	76.13	71.63	85.16	81.63	86.32	85.74	84.98	82.85	89.89	90.12
$S \rightarrow E$	71.02	71.55	70.21	70.77	70.56	70.03	78.13	79.78	87.90	88.79
$S \rightarrow F$	71.48	72.83	70.11	72.32	71.03	72.65	79.47	80.56	88.52	89.70
$Y \rightarrow Y1$	89.46	90.42	91.79	91.56	90.79	90.13	91.14	91.78	92.06	92.38
$Y \rightarrow Y2$	88.14	89.41	91.42	92.04	91.32	92.45	90.12	92.41	91.84	93.45
$Y \rightarrow Y3$	85.56	84.07	87.92	85.77	86.64	88.31	88.76	89.64	88.93	90.24

由表 6 可知, SE-DDAN 在 IEEE 39 和 IEEE 140 节点系统上的 P_{Acc} 和 G_{mean} 均优于其他模型, 并且在不同目标域数据集上均有着较高的预测准确率。DANN 通过学习对领域不变的特征表示在多个目标域上取得了较好的迁移效果。DDC 和 DAN 在迁移到目标域 C、E 和 F 时出现了负迁移现象, 这说明虽然源域和目标域是相似的, 但仅对齐分布距离的方法没有达到预想的效果。SE-DDAN 通过提高特征提取能力以及调整边缘分布和条件分布的权重, 获得了较好的自适应性和迁移性能。

5 结论

本文引入了注意力机制和动态分布自适应提出了 SE-DDAN 迁移模型更新框架, 旨在提高模型自适应性和迁移性能。在 IEEE 39 和 IEEE 140 节点系统上进行了仿真分析, 得到以下结论:

- 1) 与其他的评估模型相比, 本文通过在 CNN

中插入 SENet 模块改进特征提取器, 可以自适应地调整通道权重, 放大对当前任务有用的特征通道, 具有更好的特征提取能力和分类性能。

- 2) 当电力系统运行方式或拓扑结构发生变化时, 与其他的深度迁移学习方法相比, 本文所提的 SE-DDAN 不仅可以自适应地对齐特征分布, 还能动态地调整条件分布和边缘分布的重要性, 通过赋予两种分布不同权重, 提升了暂态稳定评估模型的迁移性能和自适应性, 为暂态稳定评估提供了新的思路和方法。

本文所提框架虽然相比于已有研究提高了迁移性能和泛化能力, 但仍然还有可提升的空间。模型的响应速度和迁移时间都影响着暂态稳定评估效果。因此, 当电力系统发生其他未知的情况时, 如何快速地生成样本和筛选最富有价值信息的样本, 都将是下一步研究的重点。

附录 A

表 A1 不同数据集的设置

Table A1 Settings for different datasets

系统	数据集	拓扑变化情况	发电和负荷水平/%	故障位置/%	故障持续时间/s
IEEE 39	S	所有线路投运	80~120	0~90	0.1~0.2
	A	线路 4-5 停运	75~125	0~80	0.1~0.2
	B	线路 4-14 停运	75~125	0~80	0.1~0.2
	C	线路 5-8 停运	75~125	0~80	0.1~0.2
	D	线路 17-27 停运	75~125	0~80	0.1~0.2
	E	线路 4-14 和 16-17 停运	75~125	0~80	0.1~0.2
	F	线路 10-11 和 4-14 停运	75~125	0~80	0.1~0.2
IEEE 140	Y	所有线路投运	80~120	0~80	0.1~0.2
	Y1	线路 53-55 和 78-79 停运	75~125	0~80	0.1~0.2
	Y2	线路 53-55、54-56 和 104-106 停运	75~125	0~80	0.1~0.2
	Y3	退出一台发电机和四条线路	75~125	0~80	0.1~0.2

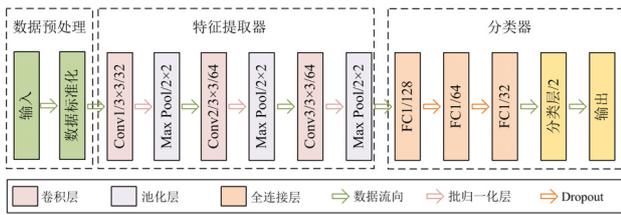


图 A1 CNN 结构
Fig. A1 CNN structure

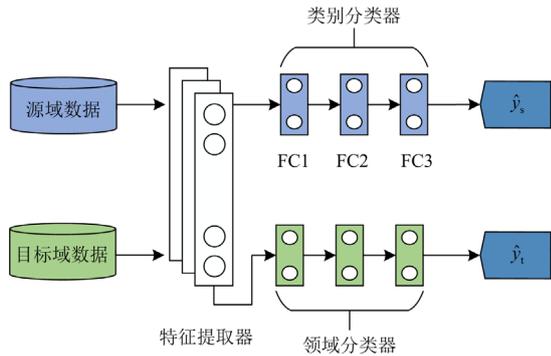


图 A2 DANN 结构
Fig. A2 DANN structure

参考文献

[1] 卓振宁, 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 Zhenning, 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.

[2] 齐金山, 姚良忠, 廖思阳, 等. 高比例新能源电力系统静态电压稳定裕度在线概率评估[J]. 电力系统保护与控制, 2023, 51(5): 47-57.
QI Jinshan, YAO Liangzhong, LIAO Siyang, et al. Online probabilistic assessment of static voltage stability margin for power systems with a high proportion of renewable energy[J]. Power System Protection and Control, 2023, 51(5): 47-57.

[3] 文劲宇, 周博, 魏利岫. 中国未来电力系统储电网初探[J]. 电力系统保护与控制, 2022, 50(7): 1-10.
WEN Jinyu, ZHOU Bo, WEI Lishen. Preliminary study on an energy storage grid for future power system in China[J]. Power System Protection and Control, 2022, 50(7): 1-10.

[4] REN C, XU Y, ZHANG Y. Post-disturbance transient stability assessment of power systems towards optimal accuracy-speed tradeoff[J]. Protection and Control of Modern Power Systems, 2018, 3(2): 1-10.

[5] 胡源, 薛松, 张寒, 等. 近 30 年全球大停电事故发生的深层次原因分析及启示[J]. 中国电力, 2021, 54(10): 204-210.
HU Yuan, XUE Song, ZHANG Han, et al. Cause analysis and enlightenment of global blackouts in the past 30 years[J]. Electric Power, 2021, 54(10): 204-210.

[6] 雷傲宇, 周剑, 梅勇, 等. “3·3”中国台湾电网大停电事故分析及启示[J]. 南方电网技术, 2022, 16(9): 90-97.
LEI Aoyu, ZHOU Jian, MEI Yong, et al. Analysis and lessons of the blackout in Chinese Taiwan Power Grid on March 3, 2022[J]. Southern Power System Technology, 2022, 16(9): 79-86.

[7] 田芳, 周孝信, 于之虹. 基于支持向量机综合分类模型和关键样本集的电力系统暂态稳定评估[J]. 电力系统保护与控制, 2017, 45(22): 1-8.
TIAN Fang, ZHOU Xiaoxin, YU Zhihong. Power system transient stability assessment based on comprehensive SVM classification model and key sample set[J]. Power System Protection and Control, 2017, 45(22): 1-8.

[8] WEHENKEL L, PAVELLA M, EUXIBIE E, et al. Decision tree based transient stability method a case study[J]. IEEE Transactions on Power Systems, 1994, 9(1): 459-469.

[9] 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.

[10] 谢清玉, 张耀坤, 李经纬. 面向智能电网的电力大数据关键技术应用[J]. 电网与清洁能源, 2021, 37(12): 39-46.
XIE Qingyu, ZHANG Yaokun, LI Jingwei. Application of key technologies of power big data in smart grids[J]. Power System and Clean Energy, 2021, 37(12): 39-46.

[11] 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.

[12] 丁石川, 厉雪衣, 杭俊, 等. 深度学习理论及其在电机故障诊断中的研究现状与展望[J]. 电力系统保护与控制, 2020, 48(8): 172-187.
DING Shichuan, LI Xueyi, HANG Jun, et al. Deep learning theory and its application to fault diagnosis of an electric machine[J]. Power System Protection and Control, 2020, 48(8): 172-187.

[13] 高发骏, 王怀远, 党然. 基于 Transformer 的暂态稳定评估模型的可解释性分析与模型更新研究[J]. 电力系

- 统保护与控制, 2023, 51(17): 15-25.
- GAO Fajun, WANG Huaiyuan, DANG Ran. Interpretability analysis and model update research of a transient stability assessment model based on Transformer[J]. Power System Protection and Control, 2023, 51(17): 15-25.
- [14] HAIDAR M A, MUSTAFA M, IBRAHIM A F, et al. Transient stability evaluation of electrical power system using generalized regression neural networks[J]. Applied Soft Computing, 2011, 11(4): 3558-3570.
- [15] 汪康康, 梅生伟, 魏巍, 等. 基于图卷积网络的快速暂态安全评估方法[J]. 电力系统保护与控制, 2023, 51(1): 43-51.
- WANG Kangkang, MEI Shengwei, WEI Wei, et al. Fast transient security assessment based on graph neural networks[J]. Power System Protection and Control, 2023, 51(1): 43-51.
- [16] 朱乔木, 党杰, 陈金富, 等. 基于深度置信网络的电力系统暂态稳定评估方法[J]. 中国电机工程学报, 2018, 38(3): 735-743.
- ZHU Qiaomu, DANG Jie, CHEN Jinfu, et al. A method for power system transient stability assessment based on deep belief networks[J]. Proceedings of the CSEE, 2018, 38(3): 735-743.
- [17] YAN R, GENG G, JIANG Q, et al. Fast transient stability batch assessment using cascaded convolutional neural networks[J]. IEEE Transactions on Power Systems, 2019, 34(4): 2802-2813.
- [18] 李楠, 朱媛, 崔莹. 考虑代价敏感的 AC-LSTM 暂态稳定评估[J]. 电力系统保护与控制, 2022, 50(22): 160-169.
- LI Nan, ZHU Yuan, CUI Ying. AC-LSTM transient stability assessment considering cost-sensitivity[J]. Power System Protection and Control, 2022, 50(22): 160-169.
- [19] 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.
- [20] 臧海祥, 郭镜玮, 黄蔓云, 等. 基于深度迁移学习的时变拓扑下电力系统状态估计[J]. 电力系统自动化, 2021, 41(15): 5107-5118.
- ZANG Haixiang, GUO Jingwei, HUANG Manyun, et al. State estimation for power systems with time-varying topology based on deep transfer learning[J]. Automation of Electric Power Systems, 2021, 41(15): 5107-5118.
- [21] 李宝琴, 吴俊勇, 张若愚, 等. 融合多类型深度迁移学习的电力系统暂态稳定自适应评估[J]. 电力自动化设备, 2023, 43(1): 184-192.
- LI Baoqin, WU Junyong, ZHANG Ruoyu, et al. Adaptive assessment of transient stability for power systems based on transfer multi-type of deep learning model[J]. Electric Power Automation Equipment, 2023, 43(1): 184-192.
- [22] 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, 2022, 20(2): 1047-1058.
- [23] 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): 5107-5119.
- 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): 5107-5119.
- [24] 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.
- [25] WANG J D, CHEN Y Q, FENG W J, et al. Transfer learning with dynamic distribution adaptation[J]. ACM Transactions on Intelligent Systems and Technology, 2020, 11(1): 1-25.
- [26] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, June 18-22, 2018, Piscataway, NJ, USA: 7132-7141.
- [27] MAATEN D V L. Accelerating t-SNE using tree-based algorithms[J]. Journal of Machine Learning Research, 2014, 15(1): 3221-3245.
- [28] 冀鲁豫, 吴俊勇, 周艳真, 等. 基于 WAMS 受扰电压轨迹簇特征的电力系统暂态稳定性预测[J]. 高电压技术, 2015, 41(3): 807-814.
- JI Luyu, WU Junyong, ZHOU Yanzhen, et al. Transient stability prediction of power system based on WAMS characteristic of perturbed voltage trajectory clusters[J]. High Voltage Engineering, 2015, 41(3): 807-814.

收稿日期: 2024-01-06; 修回日期: 2024-04-27

作者简介:

李楠(1973—), 女, 通信作者, 博士, 副教授, 研究方向为数据挖掘在电力系统中的应用; E-mail: jllinan@163.com

张帅(1998—), 男, 硕士研究生, 研究方向为人工智能算法在电力系统中的应用。E-mail: 414680207@qq.com

(编辑 姜新丽)