# 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

李宝琴<sup>1</sup>,吴俊勇<sup>1</sup>,张若愚<sup>2</sup>,强子玥<sup>1</sup>,覃柳芸<sup>1</sup>,王春明<sup>3</sup>,董向明<sup>3</sup> (1. 北京交通大学 电气工程学院,北京 100044;2. 中国长江三峡集团有限公司科学技术研究院,北京 100038; 3. 国家电网公司华中分部,湖北 武汉 430077)

摘要:针对不同类型人工智能网络应用于电力系统暂态稳定评估时精度和泛化能力不稳定、运行方式或拓扑 结构发生较大变化时评估精度下降、重新训练新模型费时费力等问题,提出一种融合多类型深度迁移学习模 型(tmDLM)的自适应评估方法,该方法融合了深度置信网络、卷积神经网络以及长短期记忆网络3种不同的 深度学习模型。将训练好的各类深度学习模型作为源域模型,当运行方式或拓扑结构发生较大变化时,采用少 量目标域样本集微调预训练模型,使其快速跟踪系统当前的运行状态,并得到tmDLM。新英格兰10机39节点 系统和华中电网的仿真结果表明:所提方法可以充分发挥各类深度学习方法的优势,具有良好的泛化能力; 六分类模型能够在判稳的同时进行稳定裕度/失稳程度等级的评估;经过迁移后的深度学习模型具有良好 的评估精度和时效性,大幅缩短了模型更新时间,实现了电力系统暂态稳定的自适应评估。

**关键词:**深度学习;集成学习;迁移学习;电力系统;暂态稳定 中图分类号:TM 712 **文献标志码:**A

#### DOI:10.16081/j.epae.202206002

# 0 引言

研究表明,大停电事故的开端往往伴随着暂态 稳定的破坏。现代电网规模的不断扩大、新能源接 入比例的不断提高,都对电力系统的安全稳定运行 提出了新的挑战<sup>[1-2]</sup>。

现有的暂态稳定评估(transient stability assessment,TSA)方法主要有时域仿真法<sup>[3]</sup>、直接法<sup>[4]</sup>和机 器学习法<sup>[5-11]</sup>。时域仿真法是最成熟的TSA方法,其 计算精度高,但其求解速度慢。直接法计算速度快, 但面对复杂电网时不易确定能量函数。与传统的 TSA方法相比,机器学习法从模式识别的角度出发, 无需构造复杂的数学解析模型,通过离线学习建立 系统特征量与暂稳态预测输出结果间的隐式映射关 系,在实际在线应用时,利用学习到的映射关系可快 速得出稳定评估结果。常用的浅层学习方法主要有 支持向量机(support vector machine,SVM)<sup>[5]</sup>、决策 树(decision tree,DT)<sup>[6]</sup>、随机森林(random forest, RF)<sup>[7]</sup>等。由于浅层学习方法对数据挖掘分析的能 力有限,在线应用时其泛化能力受到限制。

近年来,随着深度学习方法的快速发展以及由 于深度学习方法在特征提取方面的优越性能,其在 人脸识别、自然语言处理等领域广泛应用。在电力

#### 收稿日期:2021-09-26;修回日期:2022-01-04

在线出版日期:2022-06-07

基金项目:国家重点研发计划项目(2018YFB0904500);国家 电网有限公司科技项目(SGLNDK00KJJS1800236)

Project supported by the National Key Research & Development Program of China(2018YFB0904500) and the Science and Technology Project of State Grid Corporation of China (SGLNDK00KJJS1800236)

系统TSA领域:文献[8]提出一种基于深度置信网络 (deep belief network, DBN)的TSA方法,利用深层 架构对系统特征与稳定结果之间的映射关系进行 训练;文献[9]提出一种基于一维卷积神经网络 (convolutional neural network, CNN)的TSA方法,该 方法直接面向底层测量数据,实现了端到端的"时序 特征提取+暂态稳定分类";文献[10]为利用电力系 统的时序特征数据,基于长短期记忆网络(long short-term memory,LSTM)算法提出一种基于滑动时 间窗口的暂态稳定防抖动模型;文献[11]为降低主 动学习过程中选择样本的冗余度,提出一种聚类自 适应主动学习选择策略,加快了学习进程。虽然上 述深度学习方法在电力系统TSA方面取得了一定的 成果,但其忽略了模型的自适应更新能力。数据驱 动的TSA过程是动态变化的,预训练模型需要不断 适应电力系统的运行方式或拓扑结构的变化,如负 荷水平的大幅波动、发电机或线路的投退等。

迁移学习和深度学习的结合,可有效提升深度 学习模型的泛化能力和自适应能力,目前迁移学习 在电力系统暂态稳定领域的应用尚处于探索阶段。 文献[12]提出一种基于改进深度卷积生成对抗网络 的暂态稳定增强型自适应评估方法;文献[13]通过 迭代最小化训练数据与未知数据之间边缘分布和条 件分布的差异,将预训练模型迁移到未知的不同但 相关的故障;文献[14]将基于增量学习的深度继承 和基于迁移学习的广度继承应用于暂态稳定预测问 题;文献[15]基于CNN,利用新生成的最小平衡样本 集训练分类层参数,从而快速得到适用于新场景的 预测模型。

综上,为了提高模型的自适应性以及充分发挥

不同类型深度学习模型的优势,避免由于单一模型 的劣化而导致整个评估系统性能下降,本文将深度 学习、迁移学习和故障后的暂态功角稳定评估相结 合,提出一种适用于电力系统TSA的融合多类型深 度迁移学习的自适应评估方法,该方法不仅可以自 适应地跟踪系统拓扑结构和运行方式的变化,还可 以在结构和规模不同的系统之间进行迁移,输出多 样性的评估结果,大幅缩短了模型的更新训练时间, 实现了电力系统暂态稳定的自适应评估。

# 1 融合多类型深度学习的TSA模型

#### 1.1 多类型深度学习模型与TSA

暂态稳定预测的本质是求解系统稳定边界<sup>[16]</sup>, 基于机器学习的暂态稳定预测是建立输入特征*X*和 输出*Y*间的映射关系。原始训练数据集*D*<sub>m</sub>为:

$$D_{\text{pre}} = \left\{ \left( \boldsymbol{x}_{1}, \boldsymbol{y}_{1} \right), \left( \boldsymbol{x}_{2}, \boldsymbol{y}_{2} \right), \cdots, \left( \boldsymbol{x}_{N}, \boldsymbol{y}_{N} \right) \right\}$$
(1)

式中: $\mathbf{x}_i \in \mathbf{X} \in \mathbf{R}^d$ ,  $y_i \in \{C_1, C_2, \dots, C_m\}$ ( $i=1, 2, \dots, N$ ), d为输入特征的维度, N为样本总数,  $C_i$ ( $i=1, 2, \dots, m$ )为暂态稳定预测的第i个类别, m为暂态稳定预测的标签类别数, 现有研究大多将暂态稳定看作二分类问题, 即m=2, 本文将样本分为不稳定样本、较不稳定样本、临界不稳定样本、临界稳定样本、较稳定样本、很稳定样本、大类, 因此m=6。本文在判稳的同时进行稳定裕度和失稳程度等级的评估, 有效缩短模型的离线训练和在线评估时间。

基于文献[15-17]的研究成果,本文引入轨迹簇的概念,将故障切除后的发电机功角看作一个整体,研究整体的变化规律。轨迹簇特征的定义及计算方法如附录A所示,轨迹簇特征包含基本特征、变化率及曲率、加速度三大类共27个特征,这些特征将作为各类深度学习模型的输入。轨迹簇特征是发电机功角的统计特征,不会随着系统规模的增大而增加,因此各类深度学习模型的输入节点数始终为27,不受系统网络结构参数的影响。

目前应用于电力系统暂态稳定预测的常用深度 学习模型<sup>[9-12]</sup>为DBN、CNN和LSTM。DBN是一种单 层之间不连接、层与层之间全连接的基于能量的模 型,由于在训练的过程中涉及无监督学习,因此其对 标注样本的数量要求较低,可以降低数据标注的成 本,但是其难以有效利用不同时间断面之间的时序 联系;CNN通过一系列特征矩阵和卷积核进行卷积 计算,最终得到高层特征用于分类,其在学习的过程 中共享卷积核,计算量相对较小,但是池化层会丢失 部分有价值的信息;LSTM 擅于处理时间序列的数 据,深度挖掘不同数据之间的时序特性,但是随着时 间跨度增加,计算量也会增大。

针对TSA问题:CNN 在训练过程中忽略局部和

整体间的关联性,其评估结果偏风险;LSTM充分挖 掘时序特性,其评估结果偏保守;DBN具有强大的特 征提取和数据挖掘能力,其评估性能适中。由此可 见,各类深度学习模型各有优劣,很难有一种模型在 所有工况下都始终表现良好。上述3种深度学习模 型的原理及训练算法均已相当成熟,此处不再赘述。

值得说明的是,电力系统在绝大多数情况下都 处于稳定运行的状态,因此用于模型训练的稳定样本 数远多于失稳样本数,此外,失稳样本漏判和稳定样 本误判的代价往往不同。为了解决各类样本数不均 衡的问题,本文对各类深度学习模型的损失函数进 行改进,采用加权的交叉熵损失函数,加权过程为:

$$L = -\frac{1}{N} \sum_{i=1}^{N} \left( W_{\rm us} \sum_{p=1}^{3} y_i^p \, \lg \hat{y}_i^p + W_{\rm s} \sum_{q=4}^{6} y_i^q \, \lg \hat{y}_i^q \right) \quad (2)$$

式中:L为损失函数值; $y_i^e$ 为第i个样本属于第p类失 稳类别的真实标签, $p_i^e$ 为第i个样本属于第q类稳定 类别的真实标签,p取值为1、2、3,分别表示失稳类 别中的不稳定、较不稳定、临界不稳定,q取值为4、 5、6,分别表示稳定类别中的临界稳定、较稳定、很稳 定,样本的真实标签采用独热编码方式,如不稳定类 别的标签为(1,0,0,0,0),较不稳定类别的标签为 (0,1,0,0,0,0); $\hat{y}_i^e$ 分别为模型预测输出的第i个 样本属于第p类、第q类的概率; $W_{us}$ 为失稳样本的权 重, $W_s$ 为稳定样本的权重,通常 $W_{us}$ = $W_s$ =1,不区分 失稳和稳定样本的重要度,本文设置 $W_s < W_{us}$ ,两者 的具体取值与样本比例有关。

#### 1.2 融合模型的建立

根据暂态稳定分析的特性,输入数据是由相量 测量单元(phase measurement unit,PMU)采集的不 同时刻的各类电气数据,该数据为流式数据,因此需 要有效挖掘不同数据之间的时序特性和联系。若故 障切除后系统失稳,则必须快速给出评估结果,从而 给紧急控制留出充足的时间,这就要求TSA模型必 须同时满足高精度、高可靠性和快速性的要求,而单 一模型往往无法同时满足这些要求。

鉴于目前对模型的选择并没有固定的标准,不同模型在处理同一问题时各有优劣,因此为了解决不同类型人工智能网络对不同电力系统的适应性不同和评估性能不稳定的问题,本文采用融合多类型深度学习模型(multi-type of deep learning model, mDLM)的集成式概率型评估方法,避免因单一类型评估器性能劣化而导致整个评估系统性能下降。离线建模的流程见附录B图B1,具体步骤如下。

1)样本集的生成。通过时域仿真法生成包含各种运行工况、用于模型训练和测试的大样本数据集, 计算稳定裕度/失稳程度指标,并贴上对应的标签。

2)轨迹簇特征的提取及数据预处理。针对故障

切除后的发电机功角,按照前文所述方法提取不同 时间断面下的轨迹簇特征,并将特征值进行最大最 小值归一化处理,缩小不同特征之间的数值差异。

3)多类型网络评估系统。采用逐层寻优的实验 方法确定各类模型的最佳结构,逐层选择合适的节 点数,直到模型的性能趋于稳定或达到预设值。通 过实验发现,各类人工智能网络的最佳结构和最优 参数并不唯一,在实际应用中可以在各类模型中均 挑选*n*′个性能良好的结构进行集成,模型总数为*n*。

4)概率输出集成机制。本文各类深度学习模型 的输出层均为 softmax 层,将样本x预测为各类别的 概率分别设为 $P(C_1|x)$ 、 $P(C_2|x)$ 、…、 $P(C_6|x)$ 。各类 别的概率满足式(3)。

$$\sum_{i=1}^{6} P(C_i | \mathbf{x}) = 100 \%$$
(3)

若第*j*个模型对测试样本的输出概率为 ( $P_j(C_1|\mathbf{x}), P_j(C_2|\mathbf{x}), \dots, P_j(C_6|\mathbf{x})$ ),按照概率平均法 得到融合多类型模型的最终输出为( $P_{\mathbb{E}}(C_1|\mathbf{x}), P_{\mathbb{E}}(C_1|\mathbf{x})$ ),如式(4)所示。

$$P_{\mathrm{E}}(C_i|\mathbf{x}) = \frac{1}{n} \sum_{j=1}^{n} P_j(C_i|\mathbf{x}) \quad i=1, 2, \cdots, 6 \qquad (4)$$

# 2 迁移学习

186

#### 2.1 迁移学习与模型迁移方案

迁移学习是一种举一反三的能力,使机器在处 理新领域(目标域)的问题时能够根据已有领域(源 域)训练好的模型和部分数据快速训练出适合新场 景的模型。在基于深度学习的TSA中,离线训练往 往是针对特定的运行工况,当电力系统的运行方式 或拓扑结构发生较大变化时,测试数据集和训练数 据集的分布差异较大,预训练模型性能骤降甚至失 效,无法进行在线应用,此时,可利用迁移学习对预 训练模型进行更新。

本文对迁移学习的研究主要是讨论基于模型的 迁移方法,根据各类深度学习模型的结构和特点,本 文采用如下3种方案。

方案1:重新训练。保持原来各类深度学习模型结构不变,利用目标域的新训练集重新训练模型。

方案2:微调分类层。将预训练模型中除分类 层以外的结构和参数全部迁移至新模型并冻结,利 用目标域下的少量样本微调分类层的权重和偏置。

方案3:微调整个网络。将预训练模型的所有 结构和参数全部迁移至新模型,将其作为目标域模 型的初始值,在此基础上利用目标域下的少量样本 微调整个网络的权重和偏置。

# 2.2 融合迁移学习的多类型深度学习模型的构建

为了避免单一机器学习方法无法有效地表达电

力系统故障发展的时间顺序以及难以构建复杂的函数模拟系统运行特征与稳定状态输出结果之间的映射关系,同时针对电力系统的运行方式或拓扑结构发生较大变化时模型评估性能下降的问题,本文在1.2节融合mDLM方法的基础上,引入迁移学习,提出一种融合多类型深度迁移学习模型(transfer multi-type of deep learning model,tmDLM)的方法,具体的过程如下。

1)原模型训练。使用时域仿真生成的源域预训 练数据集  $D_{\text{pre}}$ 训练原模型  $M_{\text{pre}}^{(l)}(\mathbf{x})(l \in \{\text{DBN}, \text{CNN}, \text{LSTM}\})$ ,并保存  $M_{\text{pre}}^{(l)}(\mathbf{x})$ 的参数,如式(5)所示。

$$M_{\rm pre}^{(l)}(\mathbf{x}) = \operatorname{PreTrain}(D_{\rm pre})$$
(5)

式中:  $PreTrain(\cdot)$ 表示预训练过程。

2)目标域迁移。迁移预训练得到的原模型  $M_{pre}^{(l)}(\mathbf{x})$ 的结构和参数,在目标域数据集D上自适应 地调整网络参数,得到适用于目标域的TSA模型  $M^{(l)}(\mathbf{x})$ ,如式(6)所示。

$$M^{(l)}(\boldsymbol{x}) = \operatorname{Transfer}\left(M^{(l)}_{\text{pre}}(\boldsymbol{x}), D\right)$$
(6)

式中:Transfer( $\cdot$ )表示迁移更新过程。

文献[15]针对暂态稳定二分类预测问题,利用 新生成的最小平衡样本集进行迁移。但是对于多分 类评估问题而言,变步长加二分法的最小平衡样本 集的概念将不再适用,因此,本文的迁移过程是一个 不断迭代的过程,采用蒙特卡罗法针对目标域的运 行方式或拓扑结构生成少量的样本,设初始迁移样 本库D\_ 为空集,目标域迁移的具体步骤如下。

(1)首先从目标域样本集中随机筛选*N*<sub>m</sub>个样本 放入*D*<sub>m</sub>中,并从训练集中将这些样本删除。

(2)利用 $D_m$ 对原模型 $M_0$ 进行迁移学习,得到新 模型 $M_1$ 。

(3)重复以上步骤,每次迭代筛选出*N*<sub>m</sub>个样本, 对上一次的模型进行更新微调,直到模型对新场景下 的测试集预测准确率达到预设值或迭代过程中模型 性能不再提升,此时得到更新后的模型*M*<sub>new</sub>。在迁 移更新的过程中,一般在3~5次迭代后模型性能可 得到有效恢复,大幅减少了目标域所需的样本数量。

3)模型融合。通过1.2节的基于概率输出的集成机制将迁移后的多类型深度学习模型融合为一个适用于系统当前运行工况和拓扑结构的TSA模型。 值得说明的是,本文所提融合多类型深度迁移学习 方法是一种基于模型的迁移,模型迁移的过程中只 需保证源域和目标域的输入、输出维度一致即可。 针对TSA问题,本文分类模型的输入为发电机的功 角轨迹簇特征,其不会随着系统规模和发电机台数 的增加而增加,是统计特征,输入节点数始终是27, 为不同系统间基于模型的迁移奠定了基础。此外, 本文所构建评估模型的输出节点数为6,在判稳的 同时进行稳定裕度和失稳程度等级的评估。因此, 源域和目标域系统的输入、输出维度完全一致,可以 在结构和规模不同的系统间进行迁移。

#### 2.3 自适应评估流程

完善的基于数据驱动和深度学习模型的TSA包含离线训练、在线评估和周期更新3个阶段<sup>[18]</sup>。离线训练好的模型在投入在线评估后需根据系统下一时刻的运行方式或拓扑结构进行周期性的更新。一般情况下,电力系统调度人员会根据负荷预测的结果,通过优化潮流计算安排下一时刻的开停机计划,系统的拓扑结构变化可提前知道,有一定的时间裕度可提前离线生成新场景下的训练样本,并对模型进行迁移更新。3个阶段的时间联系如附录B图B2所示。特别地,当系统发生调度人员无法预知的变化时,新样本数可能不足,可以结合样本迁移和样本增强技术<sup>[12]</sup>,在较短的时间内生成用于模型迁移更新的新样本,从而保证融合模型的持续高精度预测。

融合迁移学习的暂态稳定自适应评估流程见图 1,图中 $A_{eval}$ 为评估准确率, $A_{ec}$ 为判稳准确率。当检测 到系统的运行方式或拓扑结构发生变化时,原模型  $M_0$ 的性能下降,立即启动更新过程,使用部分目标 域样本集更新 $M_0$ ,得到新模型 $M_{nev}$ 用于在线评估。



# 图 1 融合迁移学习的暂态稳定自适应评估流程 Fig.1 Flowchart of adaptive assessment of transient stability based on transfer learning

# 2.4 暂态稳定程度评估

#### 2.4.1 稳定程度指标的建立

为了使模型的输出结果更加多样化,本文根据 稳定裕度和失稳程度将输出结果划分为6类,在判 稳的同时进行稳定裕度和失稳程度等级的评估,有 效缩短模型的离线训练和在线评估的时间,同时减 少计算机的存储空间。当系统规模增加时,用于模 型训练的样本数大幅增加,此时六分类模型离线训 练时间和存储空间的优势将更加凸显。

由于极限切除时间(critical clearing time,CCT) 需要通过时域仿真法反复试探得到,因此本文根据 文献[19]构造基于转子角轨迹包络线积分的受扰程 度S,即发电机转子角轨迹簇所占的面积,将其归一 化后得到 $B_s$ 来评估样本的稳定程度,如式(7)、(8) 所示。对于失稳的样本,如果故障切除后经过较长 的时间系统才失稳,则预示着有更多的时间来采取 进一步的校正控制使系统恢复稳定。因此,本文采 用从故障切除到系统发生失稳所经历的时间 $B_{us}$ 来 评估样本的失稳程度,计算方法如式(9)所示。  $B_s \in [0,1], B_{us} \in [0,5] s, B_s 越小,系统的稳定裕度越$  $小, B_us 也越小,系统的失稳程度越严重。$ 

$$S = \int_{-1}^{t_{s}} \left( \max_{h} \delta_{h} - \min_{h} \delta_{h} \right) dt \tag{7}$$

$$B_{\rm s} = \left(S_{\rm max} - S\right) / \left(S_{\rm max} - S_{\rm min}\right) \tag{8}$$

$$B_{\rm us} = t_{\rm us} - t_{\rm cl}$$

(9)

式中: $\delta_h$ 为第h台发电机的转子角; $t_s$ 为仿真时间;  $S_{max}$ 、 $S_{min}$ 分别为受扰程度S的最大值和最小值; $t_{us}$ 为 系统发生失稳(即任意2台发电机的转子角超过 360°)的时刻; $t_{el}$ 为故障切除的时刻。

#### 2.4.2 模型性能评价

根据式(7)一(9),按取值范围将样本集进一步划 分为6类,并贴上相应的标签,如表1所示。表中B<sub>us</sub> 与B<sub>s</sub>的阈值可根据实际电网的运行工况进行调整。 离线贴标签时,稳定样本和失稳样本的标签进行分 类处理;在线应用时,根据系统的实时响应信息,可 以在判稳的同时得到系统的稳定裕度和失稳程度等 级,因此不涉及稳定和失稳的先验判别。对于不稳 定样本、较不稳定样本和临界不稳定样本,后续采取 控制措施的紧急程度不同,具体控制措施以及控制 量也不尽相同,对调度人员具有一定的参考意义。

表1 暂态稳定多级指标划分

| Table 1 | Multilevel | index | division | of | transient | stability |
|---------|------------|-------|----------|----|-----------|-----------|
|---------|------------|-------|----------|----|-----------|-----------|

|     |    |   | 5     |
|-----|----|---|-------|
| 类别  | 编号 | 指标范围  | 程度等级  |
|     | 1  | $0 \le B_{us} < 0.5 \text{ s}$                    | 不稳定   |
| 失稳类 | 2  | $0.5 \text{ s} \le B_{us} < 1 \text{ s}$          | 较不稳定  |
|     | 3  | $1 \text{ s} \leq B_{\text{us}} \leq 5 \text{ s}$ | 临界不稳定 |
|     | 4  | $0 \le B_s < 0.6$                                 | 临界稳定  |
| 稳定类 | 5  | $0.6 \le B_s < 0.8$                               | 较稳定   |
|     | 6  | $0.8 \le B_{s} \le 1$                             | 很稳定   |

用六分类的数据集来构造多类型的深度学习评估模型,评估结果可以表示为评估结果矩阵  $R=(r_{ij})_{ij}$ ,如式(10)所示。其中 $r_{ij}$ 表示实际为第i类而

预测为第 *j* 类的样本数。定义:*T*<sub>s</sub>、*T*<sub>us</sub>分别表示稳定 样本和失稳样本正确识别的数目,分别对应式(10) 后 3 行的右半部分、前 3 行的左半部分;*F*<sub>us</sub>表示将稳 定样本误判为失稳样本的样本数,对应式(10)后 3 行的左半部分;*F*<sub>s</sub>表示将失稳样本漏判为稳定样本 的样本数,对应式(10)前 3 行的右半部分。由于电 力系统暂态稳定是一个典型的非平衡分类问题,因 此构建 5 个评价指标来评估模型性能,如式(11)— (15)所示。

$$\boldsymbol{R} = \begin{bmatrix} r_{11} & r_{12} & r_{13} & r_{14} & r_{15} & r_{16} \\ r_{21} & r_{22} & r_{23} & r_{24} & r_{25} & r_{26} \\ r_{31} & r_{32} & r_{33} & r_{34} & r_{35} & r_{36} \\ r_{41} & r_{42} & r_{43} & r_{44} & r_{45} & r_{46} \\ r_{51} & r_{52} & r_{53} & r_{54} & r_{55} & r_{56} \\ r_{61} & r_{62} & r_{63} & r_{64} & r_{65} & r_{66} \end{bmatrix}$$
(10)

1)评估准确率A<sub>eval</sub>,即正确评估稳定程度等级的 样本占所有样本的比例,如式(11)所示。

$$A_{\text{eval}} = \sum_{i=1}^{6} r_{ii} / \left( T_{\text{s}} + T_{\text{us}} + F_{\text{s}} + F_{\text{us}} \right)$$
(11)

2) 判稳准确率A<sub>ee</sub>,即正确预测稳定 / 失稳的样本占所有样本的比例, 如式(12) 所示。

$$A_{\rm cc} = (T_{\rm s} + T_{\rm us}) / (T_{\rm s} + T_{\rm us} + F_{\rm s} + F_{\rm us})$$
(12)

3)安全性*S*。,即正确预测稳定的样本占所有稳定样本的比例,如式(13)所示。

$$S_{\rm e} = T_{\rm s} / \left( T_{\rm s} + F_{\rm us} \right) \tag{13}$$

4)可靠性*R*<sub>e</sub>,即正确预测失稳的样本占所有失 稳样本的比例,如式(14)所示。

$$R_{e} = T_{us} / \left( T_{us} + F_{s} \right) \tag{14}$$

5)可靠性和安全性的几何平均数 G<sub>mean</sub>,如式 (15)所示。与A<sub>ec</sub>相比,G<sub>mean</sub>值能够客观反映模型对 失稳样本的预测性能。

$$G_{\text{mean}} = \sqrt{R_{e}S_{e}} \tag{15}$$

## 3 算例分析

为了验证本文所提融合tmDLM方法的可行性 及有效性,在Tensorflow环境下搭建和改进DBN、 CNN、LSTM模型,采用Python编程语言,PC配置为: Intel(R) Core(TM) i7-8565U CPU / 8 GB RAM。

# 3.1 新英格兰10机39节点系统样本集的生成

新英格兰10机39节点系统中包含10台发电机、39条母线、12台变压器和34条交流线路,额定频率为60Hz。采用电力系统仿真软件(power system toolbox,PST)3.0生成暂态稳定样本集。为了构造较为完备的样本空间,考虑系统的常规变化,设置负荷水平为基准负荷的75%~120%,以5%为步长,相应地调整发电机出力以保证潮流收敛。在34条输电线路上设置最为严重的三相短路故障,故障位置设

置在每条输电线路全长的0~90%处,以10%为步长。 故障切除时间设置为故障后的1~11个周期,以1个 周期(即0.0167s)为步长。仿真时间为5s,共生成 37400个样本,按4:1的比例将样本随机划分为训练 集和测试集,各类样本的组成见附录B表B1。

# 3.2 融合多类型模型的性能分析

为了验证本文所提融合mDLM的性能优势以及 融合的必要性,将mDLM 与基分类器 DBN、LSTM、 CNN以及浅层学习中的SVM、DT、K近邻(K nearest neighbor, KNN)进行对比分析。针对以上各分类器, 分别选择最优参数[20]。本文各类深度学习模型数 n'=1,采用逐层寻优的方式确定性能良好的结构。 DBN的结构为81-200-100-50-30-6,受限玻尔兹曼机 (restricted Boltzmann machine, RBM) 重构的学习率 为0.8;CNN由输入层、2对卷积层和池化层、全连接 层及分类层组成,其中卷积层的大小为3×3,池化层 的大小为2×2,全连接层的节点数为1000,本文直接 将暂态稳定样本集分为6类,因此分类层的节点数 为6;LSTM的结构设置和DBN的相同,mDLM的各 基分类器均采用 Adam 优化算法,初始学习率为 0.001,训练样本数为187;SVM的核函数为径向基函 数,采用网格法和五折交叉验证对参数进行寻优; DT采用C5.0算法;KNN经寻优后的最近邻数k=18。

以故障切除后第1个周期至第3个周期的数据 集为例进行实验分析,mDLM与各基分类器以及浅 层学习方法的测试结果如表2所示。为了避免评估 结果的偶然性和随机性,各项指标均为10次抽样的 平均值。

表2 不同模型的测试结果

Table 2 Test results of different models

| 齿刑   |                    |                 | 评价指标            |                 |                    |
|------|--------------------|-----------------|-----------------|-----------------|--------------------|
| 医望   | $A_{\rm eval}$ / % | $A_{ m cc}$ / % | $S_{\rm e}$ / % | $R_{\rm e}$ / % | $G_{\rm mean}$ / % |
| mDLM | 92.31              | 98.33           | 99.09           | 97.17           | 98.13              |
| DBN  | 91.69              | 98.14           | 98.69           | 96.92           | 97.80              |
| LSTM | 90.32              | 96.84           | 96.18           | 97.35           | 96.86              |
| CNN  | 91.32              | 98.18           | 99.01           | 96.67           | 97.83              |
| SVM  | 80.59              | 94.43           | 95.58           | 92.67           | 94.11              |
| DT   | 80.32              | 94.30           | 95.54           | 92.43           | 93.97              |
| KNN  | 77.21              | 94.01           | 96.83           | 89.74           | 93.22              |

由表2可知:相较于SVM、DT、KNN,mDLM的评 估准确率 $A_{eval}$ 分别高11.72%、11.99%、15.10%,判稳 准确率 $A_{eval}$ 分别高3.90%、4.03%、4.32%,这说明 mDLM凭借各类深度学习模型强大的特征提取和数 据挖掘能力,能够有效地拟合电力系统输入特征和 暂态稳定输出结果之间的非线性映射关系,从而获 得比浅层学习更加优越的评估性能;相较于基分类 器DBN、LSTM、CNN,mDLM的评估准确率 $A_{eval}$ 分别 高0.62%、1.99%、0.99%,判稳准确率 $A_{eval}$ 分别高0.19%、 1.49%、0.15%,这说明mDLM能够取长补短,其评估 性能要优于任意一个基分类器。

为进一步说明融合模型的有效性,从测试集中 随机选取2个故障场景,利用mDLM和各基分类器 预测故障场景属于不同类别的概率,见附录B表B2 和表B3。可以发现,即使个别样本被子分类器错分, 通过模型融合也可使结果得以校正,从而在较短的 响应时间内获得相对稳定的评估结果,这说明了对 TSA问题进行多类型深度学习模型融合的必要性。

#### 3.3 最佳迁移方案的选择

为了选择一种合适有效的迁移方案,以应对预 训练集以外系统运行方式或拓扑结构的变化,以基 分类器 DBN 为例,将在基准负荷下训练的模型作为 源域模型,并将其迁移至基准负荷的120%下。将 目标域样本集按1:3的比例划分为训练集和测试 集,将训练集作为连接源域和目标域的桥梁,用于迁 移学习的训练和微调。迁移前以及采用3种方案后 模型的性能如图2所示。



Fig.2 Performance comparison among different transfer schemes

由图2可知:采用方案1重新训练后,除了安全 性指标S。优于迁移前外,其余各项指标均比迁移前 的要低,这说明当目标域的训练样本数较少时,模型 不能充分进行深层次的学习和训练,难以达到理想 的效果;采用方案2微调分类层的参数后,由于不能 给目标域样本留出充足的学习空间,因此综合指标 和迁移前的相当;采用方案3微调整个网络后的效 果最好,目标域网络有充足的学习空间,有利于适应 目标域样本的特征表示,此外,共享原模型的结构和 参数也为目标域提供了良好的学习起点。因此,在 下文的分析中,迁移方案均选择方案3。值得说明 的是,针对不同的迁移问题,最佳迁移方案往往不 同,实际中应该根据具体的应用场景和分类任务选 择合适的迁移方案。

#### 3.4 超负荷水平下的迁移效果验证

#### 3.4.1 迁移效果分析

为生成与初始训练集分布差异较大且不在模型 泛化能力范围内的新样本,以验证迁移学习的有效 性,将系统负荷水平分别调整至基准负荷的135%、 140%、145%、150%,并相应调节发电机的出力,使 得潮流计算收敛。故障设置与3.1节相同,仿真共生成14960个样本,包括3183个稳定样本和11777个 失稳样本。将超负荷样本集按1:1的比例划分为训 练集和测试集。3.2节训练好的源域mDLM在超负 荷水平样本集上的测试结果如表3所示。

表3 超负荷水平的测试结果

Table 3 Test results of overload level

| 数据集 | $A_{\rm eval}$ / % | $A_{ m cc}$ / % | $S_{\rm e}$ / % | $R_{\rm e}$ / % | $G_{\rm mean}$ / % |
|-----|--------------------|-----------------|-----------------|-----------------|--------------------|
| 训练集 | 62.53              | 90.01           | 94.05           | 88.95           | 91.46              |
| 测试集 | 62.67              | 90.07           | 93.33           | 89.17           | 91.22              |

由表3可知,原mDLM在超负荷水平下的评估 性能下降较多,尤其是评估准确率 $A_{eval}$ 和对失稳样 本的识别率 $R_{e}$ 分别低于65%和90%,评估性能大幅 下降,模型无法进行在线应用,因此需在该超负荷场 景下对模型进行迁移更新。采用方案3,每次筛选 的样本数 $N_{m}$ =187,分别从训练样本集中选择187、 374、561、…、7480个样本对原模型进行迁移。迁移 更新后的mDLM以tmDLM表示,迁移后的各基分类 器分别表示为tDBN、tCNN、tLSTM,更新后的评估准 确率 $A_{eval}$ 和判稳准确率 $A_{ec}$ 分别如图3(a)、(b)所示。



Fig.3 Transfer effect at overload level

由图 3 可知,所选择的迁移样本数越多,迁移效果越好,模型在迁移初期性能恢复越快。本文所提融合 tmDLM 方法的迁移效果优于任意一个基分类器。当用于迁移的样本数  $D_m$ =935 时,评估准确率 $A_{eval}$ 从初始的 62.67%恢复至 80.66%,判稳准确率 $A_{eval}$ 从初始的 90.07%恢复至 94.48%,这说明融合tmDLM 方法仅利用较少的目标域样本集对源域模型进行迁移更新,即可快速得到适用于系统当前运行工况的模型,从而验证了该方法的有效性。

为分析所提方法在迁移更新过程中所需样本数的优势,将其和基分类器tDBN、tCNN、tLSTM进行对比。当评估准确率A<sub>eva</sub>恢复到85%时,tmDLM和各基分类器的判稳准确率A<sub>ev</sub>均恢复到95%以上,此时融合模型所需的样本数为1870,而基分类器tDBN、tCNN、tLSTM在达到相同精度时所需的样本数分别为2244、2992、4114,因此本文所提方法相比单一的深度迁移学习算法,在训练到相同精度时所需的样本数更少,缩短了样本生成和迁移更新的时间,有利于进行在线连续的暂态稳定自适应评估。

#### 3.4.2 快速性分析

190

由于暂态稳定预测对快速性要求较高,为了分 析融合tmDLM方法的时效性,将tmDLM与采用目标 域样本集重新训练的效果进行对比。迁移与重新训 练的效果对比如附录 B 图 B3 所示。由图 B3(a)可 知,当用于迁移的样本数相同时,tmDLM的性能均 优于重新训练,进一步说明了共享原模型的参数为 新模型提供了较好的初值,使新模型具有良好的学 习起点,而对参数微调能够使模型跟踪系统当前的 运行方式。当评估准确率A\_\_\_恢复到85%以上时, 判稳准确率A.。达到95%,tmDLM所需的样本数为 1870, 微调时间为17.64 s, 而重新训练所需的样本 数为2992,训练时间为127.92s,模型自适应更新的 效率提高了7.25倍。由此可见,采用迁移的方式可 以大幅提升模型更新训练的效率。经统计,在所有 的测试样本集中,失稳样本的平均失稳时间为 1.275 s, 而所提方法评估一个样本的稳定 / 失稳程 度等级仅需0.015 ms,本文样本集的响应时间为第1 个周期至第3个周期(共0.05 s),因此在样本发生失 稳之前平均可以给调度人员留出1.225 s的时间来 采取紧急控制。此外,本文所提方法中各基分类器 是并行训练的,不会增加时间复杂度。由此可见,本 文所提方法可以满足在线TSA的快速性要求。

## 3.5 网架拓扑结构变化时的迁移效果分析

为了进一步验证本文所提融合tmDLM方法的 有效性,根据文献[15]新增如下4种运行场景,用于 模拟实际电力系统中发生大的连锁故障时,因多台 发电机组和多条线路投退而引起的系统网架拓扑结 构大的变化,并测试迁移更新后模型的评估性能。

场景A:负荷水平为基准负荷的50%,退出1台 发电机和4条线路,共生成6900个样本,随机划分 3900个样本构成训练集,剩余样本构成测试集D<sub>1</sub>。

场景B:负荷水平为基准负荷的50%,退出5台 发电机和8条线路,共生成6900个样本,随机划分 3900个样本构成训练集,剩余样本构成测试集D<sub>2</sub>。

场景C:负荷水平为基准负荷的150%,增加2台 发电机和4条线路,共生成3960个样本,随机划分 2960个样本构成训练集,剩余样本构成测试集D<sub>3</sub>。 场景D:负荷水平为基准负荷的150%,增加5台 发电机和10条线路,共生成8580个样本,随机划分 4580个样本构成训练集,剩余样本构成测试集D<sub>4</sub>。

附录B表B4展示了新的运行场景下原融合模型的测试结果和迁移更新后的效果,各场景中迁移 样本数D<sub>m</sub>=561,学习率为0.001。由表可知,当系统 运行方式或拓扑结构发生较大变化时,原来预训练 好的模型性能骤降,尤其是在场景C和场景D下模 型性能下降较多,而通过融合多类型的深度迁移学 习在仅采用561个目标域样本时,就可使模型快速 恢复到原来的评估水平。

为了突出 tmDLM 的效果,将其和文献[15]的 CNN 进行对比。在场景 C 和场景 D 下,利用 tmDLM 得到的判稳准确率A<sub>ee</sub>均优于采用同样迁移方案下 的 CNN, CNN 采用的是故障切除后第1个周期至第 15个周期的数据,可见,tmDLM 在分类难度大、响应 时间短的情况下仍有较高的判稳准确率。

在场景 D下,通过融合迁移后,评估准确率 $A_{eval}$ 比原模型提升了 34.1%,判稳准确率 $A_{ec}$ 比原模型提 升了 8.6% 且比 CNN 迁移后的高 3.3%,  $G_{mean}$  值比原 模型提升了 9.85%。因此 tmDLM 能够有效地提高 预测精度和更新效率,并且能够自适应地追踪系统 的运行方式或拓扑结构的变化,从而实现离线训练 和在线评估的精准匹配。

#### 3.6 华中电网测试结果

为了进一步说明融合的必要性以及验证本文 方法在更大规模系统中的适用性,采用华中电网的 数据进行测试。华中电网全网共有690台发电机、 8492条母线、4474条交流线路、13条直流线路以及 6022台变压器。暂态稳定计算程序选择中国电力 科学研究院开发的电力系统分析综合程序(power system analysis software package, PSASP)。以5% 为步长,设置基准负荷的75%~120%范围内的10种 负荷水平,发电机出力随负荷变化而相应调整。随 机选取4条线路,以10%为步长,设置输电线路全长 的10%~90%范围内的9种故障位置,故障类型包括 单相短路故障、两相短路故障以及三相短路故障,仿 真时间为5s。共生成14040个样本,包括10446个 稳定样本和3594个失稳样本,按式(7)-(9)计算相 应的稳定裕度和失稳程度指标,划分稳定裕度和 失稳程度等级并贴上对应的标签。将样本按照2:1 的比例随机划分为训练集和测试集,响应时间仍为 故障后的第1个周期至第3个周期。

将3.2节训练的新英格兰10机39节点系统作为 源域模型,将其预训练好的各基分类器结构和参数 作为华中电网评估模型的初始值。在此基础上采用 方案3,每次筛选目标域的样本数N<sub>m</sub>=374,迭代5次 后模型性能基本恢复到原来的评估水平。由于目标 域华中电网稳定样本数较多,样本不均衡更为明显, 迁移过程中设置损失函数的权重值W<sub>s</sub>=1、W<sub>us</sub>=3。迁 移前、重新训练、各基分类器迁移后的结果以及本文 所提方法的测试结果如附录B表B5所示。

由表B5知:由于目标域华中电网与源域新英格 兰10机39节点系统差异较大,将源域训练模型直 接应用于目标域时性能表现较差;原始模型在华中 电网的评估准确率仅为60.04%,判稳准确率仅为 84.87%, 而采用本文所提方法在源域预训练模型的 基础上进行微调,仅需13.28 s就可将评估准确率恢 复到96.89%,将判稳准确率恢复到98.99%。将本 文所提方法与重新训练的结果进行对比可知,本文 所提方法的各项评估指标均优于重新训练,重新训 练的样本数为9360,训练时间为421.08 s,本文所提 方法的模型训练更新效率比重新训练提高了31.7 倍,这说明本文所提方法不仅可自适应跟踪系统运 行方式或拓扑结构的变化,而且在结构和规模完全 不同的系统之间进行迁移也是有效的。将tDBN、 tCNN、tLSTM以及本文所提方法的结果进行对比可 知,本文所提方法的评估准确率、判稳准确率、 $G_{max}$ 比基分类器中表现最好的分别高0.44%,0.51%、 0.23%,由于各基分类器是同时并行训练的,不会花 费额外的时间,而融合机制的时间花费为ms级,因 此本文通过模型融合可在相同的时间内获得更好的 评估性能。

# 4 结论

针对单一模型泛化能力不足以及电力系统运行 工况发生较大变化时TSA模型性能下降的问题,为 了提高深度学习模型评估性能的稳定性和自适应能 力,本文提出一种融合tmDLM的评估方法,在新英 格兰10机39节点系统以及华中电网上进行仿真验 证,得到如下结论。

1)融合不同类型深度学习模型可以充分发挥各 类模型的优势,从而提高TSA输出结果的稳定性。 所提融合模型在判稳的同时进行稳定裕度/失稳程 度等级的评估,输出信息多样化,有效缩短了模型的 预测和评估时间。

2)融合tmDLM可以有效跟踪系统的运行方式 或拓扑结构的变化,且可以在结构和规模完全不同 的系统之间进行迁移。通过模型的迁移和有限的微 调,模型在目标域的评估精度和更新速度都得到大 幅提高,实现了电力系统暂态稳定的自适应评估。

对调度人员无法预知的紧急变化情况,针对新的拓扑结构快速生成最少量且最富有信息的样本并 对模型进行在线迁移更新,以及进一步考虑增加融 合的学习方法对整体评估效果的影响,将是下一步 研究工作的重点。

#### 附录见本刊网络版(http://www.epae.cn)。

#### 参考文献:

- [1] 鞠平,周孝信,陈维江,等."智能电网+"研究综述[J]. 电力自动化设备,2018,38(5):2-11.
   JU Ping, ZHOU Xiaoxin, CHEN Weijiang, et al. "Smart Grid Plus" research overview[J]. Electric Power Automation Equip-
- ment,2018,38(5):2-11.
  [2] 黄丹,孙华东,周勤勇,等.基于响应轨迹最大李雅普诺夫指数 动态特征的暂态稳定在线监测[J].电力自动化设备,2020,40 (4):48-55.
  HUANG Dan,SUN Huadong,ZHOU Qinyong, et al. Online monitoring of transient stability based on largest Lyapunov exponent dynamic characteristics of response trajectory[J]. Electric Power Automation Equipment,2020,40(4):48-55.
- [3] 吴红斌,丁明.用于电力系统暂态稳定仿真的可变步长牛顿法
   [J].中国电机工程学报,2010,30(7):36-41.
   WU Hongbin,DING Ming. Newton method with variable step size for power system transient stability simulation [J]. Proceedings of the CSEE,2010,30(7):36-41.
- [4] XUE Y, VAN CUSTEM T, RIBBENS-PAVELLA M. Extended equal area criterion justifications, generalizations, applications [J]. IEEE Transactions on Power Systems, 1989, 4(1):44-52.

 [5] 刘俐,李勇,曹一家,等. 基于支持向量机和长短期记忆网络的 暂态功角稳定预测方法[J]. 电力自动化设备,2020,40(2): 129-139.
 LIU Li,LI Yong,CAO Yijia, et al. Transient rotor angle stability prediction method based on SVM and LSTM network[J].

- Electric Power Automation Equipment, 2020, 40(2):129-139.
  [6] 张晨宇,王慧芳,叶晓君. 基于 XGBoost 算法的电力系统暂态 稳定评估[J]. 电力自动化设备, 2019, 39(3):77-83, 89.
  ZHANG Chenyu, WANG Huifang, YE Xiaojun. Transient stability assessment of power system based on XGBoost algorithm[J]. Electric Power Automation Equipment, 2019, 39(3): 77-83.89.
- [7] KAMWA I, SAMANTARAY S R, JOOS G. Catastrophe predictors from ensemble decision-tree learning of wide-area severity indices[J]. IEEE Transactions on Smart Grid, 2010, 1(2): 144-158.
- [8]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.
- [9]高昆仑,杨帅,刘思言,等.基于一维卷积神经网络的电力系统 暂态稳定评估[J].电力系统自动化,2019,43(12):18-26.
   GAO Kunlun,YANG Shuai,LIU Siyan, et al. Transient stability assessment for power system based on one-dimensional convolutional neural network[J]. Automation of Electric Power Systems,2019,43(12):18-26.
- [10] LI B Q, WU J Y, HAO L L, et al. Anti-jitter and refined power system transient stability assessment based on longshort term memory network[J]. IEEE Access, 8:35231-35244.
- [11] 卢东昊,王莉,张少凡,等. 基于聚类自适应主动学习的电力系统暂态稳定评估[J]. 电力自动化设备,2021,41(7):176-181.
  LU Donghao,WANG Li,ZHANG Shaofan, et al. Transient stability assessment of power system based on clustering adaptive active learning [J]. Electric Power Automation Equipment,2021,41(7):176-181.
- [12] 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 Baogin, WU Junyong, QIANG Ziyue, et al. Enhanced adaptive assessment on transient stability of power system based on improved deep convolutional generative adversarial network [J]. Automation of Electric Power Systems, 2022, 46(2):73-82.

[13] 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.

192

- [14] 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.
- [15] 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):2196-2205. 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): 2196-2205.
- [16] 李宝琴,吴俊勇,邵美阳,等. 基于集成深度置信网络的精细化 电力系统暂态稳定评估[J]. 电力系统自动化, 2020, 44(6): 17-26 LI Baoqin, WU Junyong, SHAO Meiyang, et al. Refined tran-

sient stability evaluation for power system based on ensemble deep belief network [J]. Automation of Electric Power Systems, 2020, 44(6): 17-26.

[17] 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.

- [18] ZHOU Y Z, GUO Q L, SUN H B, et al. A novel data-driven approach for transient stability prediction of power systems considering the operational variability[J]. International Journal of Electrical Power & Energy Systems, 2019, 107: 379-394.
- [19] 刘友波,刘俊勇, Gareth Taylor, 等. 面向同步相量轨迹簇规则 的电力系统暂态稳定实时评估[J]. 中国电机工程学报,2011, 31(16):32-39.

LIU Youbo, LIU Junyong, TAYLOR G, et al. Rule-based combined algorithm for power system real-time transient stability assessment using synchronized phasor trajectory clusters [J]. Proceedings of the CSEE, 2011, 31(16): 32-39.

[20] 王怀远,陈启凡. 基于堆叠变分自动编码器的电力系统暂态稳 定评估方法[J]. 电力自动化设备,2019,39(12):134-139. WANG Huaiyuan, CHEN Qifan. Transient stability assessment method of electric power systems based on stacked variational auto-encoder[J]. Electric Power Automation Equipment, 2019, 39(12):134-139.

#### 作者简介:



李宝琴(1996-),女,博士研究生,主 要研究方向为机器学习、人工智能在电力系 统暂态稳定中的应用(E-mail: 19117011@ bjtu.edu.cn);

吴俊勇(1966-),男,教授,博士研究 生导师,博士,通信作者,主要研究方向为智 能电网运行与控制、综合能源系统、大功率 储能变流器、人工智能在电力系统中的应用 等(E-mail:wujy@bjtu.edu.cn)。

(编辑 王锦秀)

# Adaptive assessment of transient stability for power system based on transfer multi-type of deep learning model

LI Baoqin<sup>1</sup>, WU Junyong<sup>1</sup>, ZHANG Ruoyu<sup>2</sup>, QIANG Ziyue<sup>1</sup>, QIN Liuyun<sup>1</sup>,

WANG Chunming<sup>3</sup>, DONG Xiangming<sup>3</sup>

(1. School of Electrical Engineering, Beijing Jiaotong University, Beijing 100044, China;

2. Institute of Science and Technology of China Three Gorges Corporation, Beijing 100038, China;

3. Central China Branch of State Grid Corporation of China, Wuhan 430077, China)

Abstract: Aiming at the problems that the accuracy and generalization ability are unstable when different types of artificial intelligence networks apply in transient stability assessment of power system, the assessment accuracy reduces when the operation mode or topological structure changes greatly, and the time and effort are wasted when retraining a new model, an adaptive assessment method integrating with a transfer multi-type of deep learning model(tmDLM) is proposed, which integrates with three different deep learning models of deep belief network, convolutional neural network and long short-term memory network. Each type of the trained deep learning model is taken as the source domain model, when the operation mode or the topological structure changes largely, a small number of the object domain sample sets are used to finetuning the pre-trained model, making it quickly track the current operation state of the system, then the tmDLM is obtained. The simulative results of New England 10-machine 39-bus system and the Central China Power Grid show that the proposed method can make full use of the advantages of each type of deep learning method with good generalization ability, the six-classification model can assess the stability margin / instability degree while judging the stable state, the deep learning model has good assessment accuracy and timeliness after transfer learning, which greatly reduces the update time of the model and realizes self-adaptive assessment of transient stability of power system.

Key words: deep learning; ensemble learning; transfer learning; electric power systems; transient stability

附录 A:

| Table A1 Definition of trajectory cluster features |            |    |          |     |            |  |  |  |
|--|------------|----|----------|-----|------------|--|--|--|
|  | 基本特征       |    | 变化率及曲率   | 加速度 |            |  |  |  |
| 序号   | 特征名称       | 序号 | 特征名称     | 序号  | 特征名称       |  |  |  |
| 1  | 质心         | 10 | 质心变化率    | 22  | 质心变化加速度    |  |  |  |
| 2  | 离散度        | 11 | 离散度变化率   | 23  | 离散度变化加速度   |  |  |  |
| 3  | 上包络线       | 12 | 上包络线变化率  | 24  | 上包络线变化加速度  |  |  |  |
| 4  | 下包络线       | 13 | 下包络线变化率  | 25  | 下包络线变化加速度  |  |  |  |
| 5  | 中心线        | 14 | 中心线变化率   | 26  | 中心线变化加速度   |  |  |  |
| 6  | 上包络线与质心线之差 | 15 | 包络线高度变化率 | 27  | 包络线高度变化加速度 |  |  |  |
| 7  | 下包络线与质心线之差 | 16 | 轨迹曲率     |     |            |  |  |  |
| 8  | 包络线高度      | 17 | 质心曲率     |     |            |  |  |  |
| 9  | 中心线与质心之差   | 18 | 离散度曲率    |     |            |  |  |  |
|  |            | 19 | 上包络线曲率   |     |            |  |  |  |
|  |            | 20 | 下包络线曲率   |     |            |  |  |  |
|  |            | 21 | 中心线曲率    |     |            |  |  |  |

表 A1 轨迹簇特征的定义

# 1) 基本特征。

轨迹簇的相量矩阵用 $\left(x_{ij}\right)_{uxv}$ 表示,其中u为轨迹的条数,v为采样的周期数。

质心定义为: 
$$c_j = \frac{1}{u} \sum_{i=1}^{u} x_{ij}$$
, 对应某一列的均值。  
离散度定义为:  $d_j = \frac{1}{u} \sum_{i=1}^{u} |x_{ij} - c_j|^2$   
上包络线:  $\{\max\{x_j\}\}(j = 1, 2, \cdots, v)$   
下包络线:  $\{\min\{x_j\}\}(j = 1, 2, \cdots, v)$   
中心线:  $m_{cj} = \frac{1}{2} (\max(x_j) + \min(x_j))(j = 1, 2, \cdots, v)$ 

2) 变化率及曲率特征。

变化率:  $r_j = \frac{1}{z} |x_{j+1} - x_j| (j = 1, 2, \dots, v-1), z$ 为周期。 采用插值技术定义曲率特征:  $C_j = \frac{1}{z^2} \left[ \sum_{i=1}^{u} (x_{i,j-1} - 2x_{i,j} + x_{i,j+1})^2 \right]^{1/2} (j = 2, 3, \dots, v-1)$ 

3) 加速度特征。

$$a_{cj} = \frac{1}{z} [r_{c,j+1} - r_{c,j}] (j = 1, 2, \dots, v - 2), \quad \pm r_{c,j} \equiv \pi$$

附录 B:



Fig.B1 Fusion multi-type deep learning model



图 B2 3 个阶段的时间联系 Fig.B2 Temporal relationship of three important stages

| 表 B1 | 样本集合的组成 |
|------|---------|
| K DI | 计个未口的组织 |

| Table B1 | Com | position | of | samp | le | set |
|----------|-----|----------|----|------|----|-----|
|          |     |          |    |      |    |     |

|      |        |       | 失稳样本  |       |       | 稳定样本  |        |
|------|--------|-------|-------|-------|-------|-------|--------|
| 样本集合 | 总数     | 不稳定   | 较不稳定  | 临界不稳定 | 临界稳定  | 较稳定   | 很稳定    |
| 总样本  | 37 400 | 9 880 | 3 092 | 1 716 | 2 984 | 7 275 | 12 453 |
| 训练集  | 29 920 | 7 876 | 2 472 | 1 367 | 2 357 | 5 835 | 10 013 |
| 测试集  | 7 480  | 2 004 | 620   | 349   | 627   | 1 440 | 2 440  |

| Table B2 Prediction probability of mDLM and base classifier under Scenario1 |                      |                      |                      |         |                      |                       |      |  |  |  |
|---|----------------------|----------------------|----------------------|---------|----------------------|-----------------------|------|--|--|--|
|   |                      |                      |                      |         |                      |                       |      |  |  |  |
| 模型  |                      | 失稳类                  |                      |         | 稳定类                  |                       | 真实类别 |  |  |  |
|   | 1                    | 2                    | 3                    | 4       | 5                    | 6                     | -    |  |  |  |
| DBN   | 1.7×10 <sup>-7</sup> | 6.4×10 <sup>-5</sup> | 0.001 7              | 0.998 2 | 7.1×10 <sup>-5</sup> | $1.4 \times 10^{-10}$ |      |  |  |  |
| LSTM  | 0.953 4              | 0.010 3              | 3.3×10 <sup>-4</sup> | 0.034 5 | 0.001 5              | 1.9×10 <sup>-5</sup>  | 4    |  |  |  |
| CNN   | $6.5 \times 10^{-4}$ | 0.044 7              | 0.235 9              | 0.716 6 | 0.002 0              | $1.5 \times 10^{-8}$  | 4    |  |  |  |
| mDLM  | 0.318 0              | 0.018 4              | 0.079 3              | 0.583 1 | 0.001 2              | 6.4×10 <sup>-6</sup>  |      |  |  |  |

# 表 B2 场景1 下融合模型和各基分类器的预测概率

| 表 B3  | 场暑2 | 下融合模            | 通和各基ゲ | > 举器的预 | 测概率       |
|-------|-----|-----------------|-------|--------|-----------|
| AX DJ |     | 1 1 1 1 二 1 二 六 | 主作日生人 |        | ///////// |

| Table B3 Prediction probability of mDLM and base classifier under Scenario2 |         |         |                      |                      |                       |                       |      |  |  |  |
|---|---------|---------|----------------------|----------------------|-----------------------|-----------------------|------|--|--|--|
|   |         |         | 预测                   | 概率                   |                       |                       |      |  |  |  |
| 模型  |         | 失稳类     |                      |                      | 稳定类                   |                       | 真实类别 |  |  |  |
|   | 1       | 2       | 3                    | 4                    | 5                     | 6                     |      |  |  |  |
| DBN   | 0.268 0 | 0.732 0 | 2.0×10 <sup>-5</sup> | 7.3×10 <sup>-9</sup> | $1.1 \times 10^{-17}$ | 2.4×10 <sup>-27</sup> |      |  |  |  |
| LSTM  | 0.054 4 | 0.437 9 | 0.497 5              | 0.007 9              | 0.002 3               | 5.8×10 <sup>-6</sup>  | 2    |  |  |  |
| CNN   | 0.637 0 | 0.361 9 | 0.001 3              | 4.7×10 <sup>-5</sup> | $1.8 \times 10^{-8}$  | 1.6×10 <sup>-21</sup> | 2    |  |  |  |
| mDLM  | 0.320 0 | 0.511 1 | 0.166 0              | 0.002 6              | 0.000 8               | 1.9×10 <sup>-6</sup>  |      |  |  |  |



# 图 B3 迁移与重新训练的效果对比

Fig.B3 Effect comparison between transfer and retraining

# 表 B4 各场景下的融合迁移效果

Table B4 Transfer effect under each scenario

| 场景 | 模型  | $A_{ m eval}$ /% | $A_{ m cc}$ /% | $S_{\rm e}$ /% | $R_{\rm e}^{~/\%}$ | $G_{ m mean}$ /% |
|----|-----|------------------|----------------|----------------|--------------------|------------------|
|    | 原模型 | 60.13            | 95.1           | 94.6           | 97.4               | 96.0             |
| A  | 迁移后 | 97.2             | 98.5           | 98.6           | 98.0               | 98.3             |
| р  | 原模型 | 72.3             | 90.1           | 93.3           | 90.3               | 91.8             |
| В  | 迁移后 | 97.2             | 99.1           | 98.8           | 99.6               | 99.2             |
|    | 原模型 | 61.1             | 91.6           | 92.3           | 90.1               | 91.2             |
| С  | CNN | —                | 96.7           | _              | —                  | _                |
|    | 迁移后 | 96.8             | 98.2           | 98.1           | 98.7               | 98.4             |
|    | 原模型 | 62.3             | 89.9           | 87.6           | 90.1               | 88.8             |
| D  | CNN | —                | 95.2           | _              | —                  | —                |
|    | 迁移后 | 96.4             | 98.5           | 98.2           | 99.1               | 98.65            |

# 表 B5 华中电网测试结果

| Table B3 Test results of Central Clinia Power Grid |                   |                 |                  |        |
|--|-------------------|-----------------|------------------|--------|
| 模型   | $A_{\rm eval}$ /% | $A_{\rm cc}$ /% | $G_{ m mean}$ /% | 更新时间/s |
| 迁移前  | 60.04             | 84.87           | 72.09            | —      |
| 重新训练   | 96.04             | 98.39           | 97.42            | 421.08 |
| tDBN   | 96.45             | 98.48           | 97.64            | 11.51  |
| tCNN   | 96.22             | 98.27           | 98.01            | 13.27  |
| tLSTM  | 96.14             | 98.05           | 97.53            | 12.23  |
| 本文所提方法   | 96.89             | 98.99           | 98.24            | 13.28  |

Table B5 Test results of Central China Power Grid