

DOI: 10.11918/202506048

两阶段解耦与多教师蒸馏的电力系统主导失稳模式识别

李曼¹, 王聪¹, 张宏立¹, 马萍¹, 张绍华¹, 龚丰金²

(1. 新疆大学 智能科学与技术学院, 乌鲁木齐 830017; 2. 新疆大学 电气工程学院, 乌鲁木齐 830017)

摘要: 电力系统的暂态稳定性对保障电网安全运行和持续供电至关重要, 而准确识别电力系统暂态主导失稳模式(DIM)是制定有效应急控制策略的关键。文中针对电力系统暂态特征数据分布不平衡问题, 提出了一种两阶段解耦学习与多教师蒸馏框架(TSDM)。该框架采用两阶段解耦训练策略, 实现了表征学习和分类器训练的协同优化。首先, 采用实例采样训练多个教师模型, 以学习电力系统暂态特征数据的全局特征分布。其次, 采用类平衡采样训练学生模型, 通过特征蒸馏从教师模型中迁移高阶特征表示, 而非直接复用其分类器权重, 从而缓解偏差传递问题。同时对特征向量和分类器权重分别进行归一化处理, 有效消除了因特征尺度差异而导致的预测偏差。最后, 以可分离 Transformer 模块作为骨干网络, 该模块通过参数共享机制和注意力优化设计, 能够准确捕捉长时间序列的时空关联特征, 使特征提取性能不受序列长度影响。基于 CEPRI-36 节点系统算例的仿真结果表明, 所提方法在电力系统暂态主导失稳模式识别任务中达到 98.61% 的分类准确率, 尤其在少数类样本识别上展现出显著优势, 为电力系统暂态稳定分析提供了有效的解决方案。

关键词: 两阶段训练策略; 多教师模型; 特征蒸馏; 主导失稳模式; 电力系统仿真分析; 样本不平衡

中图分类号: TP183; TM715

文献标志码: A

文章编号: 0367-6234(2026)04-0117-11

Identification of dominant instability mode in power systems via two-stage decoupling and multi-teacher distillation

LI Man¹, WANG Cong¹, ZHANG Hongli¹, MA Ping¹, ZHANG Shaohua¹, GONG Fengjin²

(1. School of Intelligence Science and Technology, Xinjiang University, Urumqi 830017, China;

2. School of Electrical Engineering, Xinjiang University, Urumqi 830017, China)

Abstract: The transient stability of power systems is crucial for ensuring secure grid operation and continuous power supply, and accurately identifying the transient dominant instability mode (DIM) of power systems is key to formulating effective emergency control strategies. To address the problem of imbalanced distribution of power system transient characteristic data, this paper proposed a two-stage decoupling learning and multi-teacher distillation (TSDM) framework. This framework employed a two-stage decoupling training strategy to achieve the collaborative optimization of representation learning and classifier training. First, instance sampling was used to train multiple teacher models to learn the global feature distribution of the power system transient characteristic data. Second, class-balanced sampling was adopted to train the student model, which transferred high-order feature representations from the teacher models through feature distillation rather than directly reusing their classifier weights, thereby mitigating the problem of bias propagation. Simultaneously, normalization was applied to the feature vectors and classifier weights, respectively, effectively eliminating the prediction biases caused by differences in feature scales. Finally, a separable Transformer module served as the backbone network; through a parameter sharing mechanism and attention optimization design, this module could accurately capture the spatiotemporal correlation features of long time sequences, ensuring that the feature extraction performance was not affected by sequence length. Simulation results based on the CEPRI-36 node system case show that the proposed method achieves a classification accuracy of 98.61% in the recognition of DIM of power systems, particularly demonstrating a significant advantage in the recognition rate of minority class samples, and it provides an effective solution for power system transient stability analysis.

Keywords: two-stage training strategy; multi-teacher model; feature distillation; dominant instability mode; power system simulation analysis; sample imbalance

收稿日期: 2025-06-19; 录用日期: 2025-08-15; 网络首发日期: 2026-03-24

网络首发地址: <https://link.cnki.net/urlid/23.1235.t.20260323.1736.015>

基金项目: 国家自然科学基金(52267010); 新疆维吾尔自治区自然科学基金(2022D01E33); 天山英才培养计划(2023TSYCCX0037)

作者简介: 李曼(1999—), 女, 硕士研究生; 王聪(1989—), 女, 教授, 博士生导师; 张宏立(1972—), 男, 教授, 博士生导师;

马萍(1994—), 女, 副教授, 博士生导师

通信作者: 王聪, wangc@xju.edu.cn

在全球应对气候变化的背景下,能源系统正面临深刻的低碳转型。为大幅降低温室气体排放,各国正积极推进能源结构调整,逐步淘汰化石燃料并构建新型低碳能源体系^[1]。在这一转型过程中,电力系统作为关键能源载体,承担着整合风电、光伏、水电,以及核电等清洁能源的重要使命,实现清洁电力向终端用户的高效输送^[2]。为确保电力供应的安全稳定运行^[3],电力企业必须开展全面的仿真分析,通过模拟各类预期故障场景来评估系统稳定性并识别潜在风险^[4]。现代仿真技术已能高效生成海量仿真数据,但仿真数据的分析仍高度依赖人工处理,导致分析效率低下且成本高昂。其中,识别不稳定仿真案例的主导失稳模式(dominant instability mode, DIM)是仿真数据分析的核心任务之一。DIM的判定能够明确系统失稳的根本原因,即区分是功角失稳还是电压失稳主导,从而为后续控制策略的制定提供关键依据^[5]。

对于小型电力系统,其 DIM 可通过解析方法直接判定。然而,在实际大规模电力系统中,由于包含众多大容量发电机组,其稳定性问题呈现出显著的复杂性。在这种复杂场景下,转子功角失稳与电压失稳往往相互耦合,且表现出相似的动态特征^[6],导致单一不稳定工况中可能同时存在两种失稳现象。这种复杂的交互作用使得传统的解析方法或基于简单规则的计算机程序难以准确区分失稳类型^[7],特别是在现代大规模互联电力系统中表现尤为突出。因此,当前电力系统仿真分析中的 DIM 识别仍高度依赖专家经验,需要专业人员通过人工判读仿真数据来作出判断,这种方法不仅效率低下、成本高昂,而且存在较大的人为误差风险^[8-9]。

近年来,深度学习技术^[10-11]已成为推动电力系统人工智能应用的重要驱动力,在稳定分析和 DIM 识别领域展现出显著优势。在暂态稳定评估方面,研究人员已成功应用多种深度学习模型,包括深度置信网络^[12]、门控循环单元^[13]、卷积残差记忆网络^[14-15]等。在电压稳定评估方面,递归神经网络模型也取得了良好的应用效果^[16-17]。在 DIM 识别方面,文献[7]提出的挤压激励卷积神经网络和文献[8]开发的图注意力网络模型,为解决这一关键问题提供了创新的技术路径。

然而,电力系统仿真数据普遍存在严重的类别不平衡问题,其中稳定样本显著多于不稳定样本。这种不平衡的数据分布容易导致训练后的模型对多数类产生过度偏好,从而严重削弱其对少数类的识别能力,给 DIM 识别研究带来了显著的技术挑战。现阶段改善数据不平衡的影响主要采用数据增

强^[18-19]和代价敏感学习^[20-21]的方法,马彬喻等^[22]提出条件变分自编码器和生成对抗网络的深度学习框架,通过编码器、生成器、鉴别器和分类器 4 个部分协同工作,生成高质量的失稳样本。解治军等^[23]通过引入两个权重因子以改进交叉熵损失函数,增强对暂态失稳样本和暂态稳定边界样本这两类不平衡样本的关注度。肖龙等^[24]通过采用焦点损失函数解决样本不平衡问题,该函数通过引入样本类别权重因子平衡类别差异,并引入难易样本调制因子增加对稳定边界样本的关注度,从而解决了模型的倾向性问题和难分类样本的易错判问题。赵小强等^[25]通过引入最大安全近邻数和局部密度的概念,将少数类样本划分为安全样本、边界样本和离群点,并采用加权采样概率和自适应 K 近邻参数调整的方式,对不同类型的样本进行针对性的过采样,有效解决了样本不平衡问题,提升了分类器性能。然而,现有不平衡数据处理方法的研究主要集中于暂态稳定二分类问题,即判断系统稳定、失稳,而针对 DIM 多分类识别任务的研究仍存在明显空白。与暂态稳定评估不同, DIM 识别需要进一步区分具体的失稳类型,如功角失稳、电压失稳等,这使得数据不平衡问题呈现出新的特征:不仅存在稳定样本与失稳样本之间的类别不平衡,各失稳模式子类,如功角失稳、电压失稳之间也存在显著的数量差异且不同失稳模式的动态特征可能存在交叉和相似性,各类失稳模式对系统的影响程度和控制代价不同,简单的类别权重分配可能无法反映实际工程需求。

因此,在当前电力系统 DIM 识别研究中,尚存在以下关键问题亟待解决:1) 如何有效提取各失稳模式特征相互耦合、长时序特性显著的数据集中具有判别性的动态特征。2) 如何解决类别不平衡数据导致的模型训练偏差问题,提升少数类失稳模式的识别准确率。为此,本文提出了一种两阶段解耦学习与多教师蒸馏(two-stage decoupling learning and multi-teacher distillation, TSDM)框架,该框架通过两阶段解耦训练策略,实现了表征学习和分类器训练的协同优化。首先,采用实例采样策略,对训练数据集集中的所有样本赋予同等关注度,同时训练多个互补的教师模型,使其能够学习更多样化的特征表示,这种特征表示对整个数据集的分布有较好的适应性,为知识蒸馏提供“知识”。其次,采用类平衡采样更多地去关注样本数量较少的类别,并允许从头开始训练一个新的特征提取器,使用特征蒸馏策略实现教师模型特征空间到学生模型的高效迁移,该融合机制不仅增强了学生模型的特征表示能力,还通过提升特征表示的多样性有效降低了过拟合的风

险。最后,在网络架构方面,采用可分离 Transformer 模块,能够有效建模长时间序列的时空依赖关系从而保持特征提取性能,为保障电力系统安全稳定运行提供了可靠的智能分析手段。

1 基于知识蒸馏的两阶段训练策略

1.1 两阶段采样策略

采样策略的优化对提升模型泛化能力至关重要,针对类别不平衡数据导致的模型偏差问题,本文采用以下两种采样策略。

1.1.1 实例采样策略

该策略以均匀概率从整个数据集中随机抽取样本组成每个训练批次。然而,由于数据分布的不平衡特性,多数类样本的采样频率显著高于少数类,导致模型在少数类上容易出现欠拟合问题。具体而言,设 P_a 为从第 a 类中采样一个样本的概率,则在实例采样策略下采样概率可表示为

$$P_a = \frac{n_a}{\sum_{i=1}^D n_i} \quad (1)$$

式中: D 为数据集的类别数量, n_i 为类别 i 的样本总数。这一采样方式使得多数类样本的采样概率高于少数类,从而影响模型在类别不平衡数据上的学习效果。

1.1.2 类平衡采样策略

该策略通过均衡各类别的采样概率来缓解数据不平衡问题。各类别中每个样本的采样概率 P_c 可表示为

$$P_c = \frac{1}{D \times n_i} \quad (2)$$

式中, $c \in \{1, 2, \dots, D\}$ 。尽管这一策略有效平衡了训练数据的分布,但也带来了新的问题:多数类样本的采样频率被显著降低,而少数类样本的采样频率则相对提高。这种采样方式虽然改善了少数类的学习效果,但可能导致模型在多数类上的训练不足,从而倾向于对少数类产生过拟合现象。

为兼顾两种采样策略的优势,采用两阶段训练框架:第1阶段使用实例采样策略学习泛化性特征,第2阶段采用类平衡采样策略提升少数类识别能力。然而,这种设计仍存在两个关键问题:一是实例采样可能导致少数类特征学习不足,二是类平衡采样可能造成多数类性能下降。这表明简单的两阶段组合仍需优化,需在策略过渡和特征平衡机制上进行更深入的研究。

1.2 两阶段蒸馏策略

为解决上述采样策略存在的问题,引入蒸馏学习。1)通过实例采样策略训练多教师模型。2)在

类平衡采样的基础上结合特征蒸馏损失从头开始训练学生模型。该特征蒸馏损失函数使学生模型学习教师模型的特征表达能力,并优化特征提取以提升分类性能。该设计结合了第1阶段知识和类平衡策略,进一步提高了模型表现。特征蒸馏损失项为

$$l_{\text{F}}(\mathbf{v}, \mathbf{x}) = \beta(1 - \cos(\mathbf{v}, \mathbf{x})) \quad (3)$$

式中: β 为缩放因子, \mathbf{v} 为学生模型特征, \mathbf{x} 为教师模型特征。蒸馏学习是通过最小化学生模型与教师模型之间的余弦距离实现。

单教师模型损失函数如下:

$$L_{\text{Single}} = \sum_{i=1}^n (1 - \alpha) \cdot l(\sigma(\mathbf{z}_i), y_i) + \alpha \cdot (\beta l_{\text{F}}(h(\mathbf{v}_i), \hat{\mathbf{v}}_i)) \quad (4)$$

式中: $l(\cdot)$ 为交叉熵损失函数, $\mathbf{z}_i = \phi_{\theta, w}(x_i)$ 为模型的输出, $\sigma(\cdot)$ 为 Softmax 激活函数, \mathbf{v}_i 为学生模型对第 i 个样本提取的特征, $\hat{\mathbf{v}}_i = \hat{f}_{\hat{\theta}}(x_i)$ 为教师模型特征, α 为蒸馏权重, $h: \mathbf{R}^d \rightarrow \mathbf{R}^{d \times H}$ 为线性层,将学生模型特征映射到与教师模型特征相同的维度,以便于计算余弦距离。

在数据分布不平衡的情况下,教师模型的分器往往会表现出对多类数据的显著偏好。为此,本文提出的特征蒸馏方法着重引导学生模型学习教师模型的特征提取机制,而非直接继承其存在偏差的分类决策,从而有效缓解模型对多数类的倾向性问题。分类蒸馏损失函数为

$$L_{\text{classify}} = \sum_{i=1}^n (1 - \alpha) \cdot l(\sigma(\mathbf{z}_i), y_i) + \alpha \cdot T^2 \cdot l(\sigma(\mathbf{z}_i/T), \sigma(\hat{\mathbf{z}}_i/T)) \quad (5)$$

式中: $\hat{\mathbf{z}}_i = \hat{\phi}_{\hat{\theta}, \hat{w}}(x_i)$ 为教师模型输出, T 为温度系数。

本文方法实现了从教师模型到学生模型的知识迁移,为充分挖掘数据特征,通过添加不同程度的随机高斯噪声,训练了具有差异性的教师模型群体。通过集成多个教师模型的知识,训练出的学生模型不仅能够学习到更丰富的特征表示,还能有效缓解过拟合问题。多教师模型损失函数为

$$L_{\text{Multi}} = \sum_{i=1}^n (1 - \alpha) \cdot l(\sigma(\mathbf{z}_i), y_i) + \alpha \cdot (\beta l_{\text{F}}(h(\mathbf{v}_i), \hat{\mathbf{V}}_i)) \quad (6)$$

式中, $\hat{\mathbf{V}}_i = [\hat{\mathbf{v}}_i^1, \dots, \hat{\mathbf{v}}_i^H]$ 表示连接了 H 个教师模型的特征。

2 基于两阶段解耦与多教师蒸馏的电力系统主导失稳模式识别

2.1 基于可分离 Transformer 的特征提取器

为了更有效地建模长时间序列的时空依赖关系,教师模型与学生模型均采用可分离 Transformer 作为骨干网络。其结构如图1所示。




图 1 骨干网络结构

Fig. 1 Structure of backbone network

可分离自注意力机制 (separable self-attention, SSA) 是在传统多头自注意力机制 (multi-headed self-attention, MHA) 的基础上的扩展和改进, 其结构图如图 2 所示。由图 2 可以看出, 相较于 MHA 采用缩放点积注意力计算 k 个 token 间的全局上下文相关性, 并借助批量化矩阵乘法及 Softmax 函数生成注意力权重矩阵, SSA 采用了一种潜在 token 依赖的自

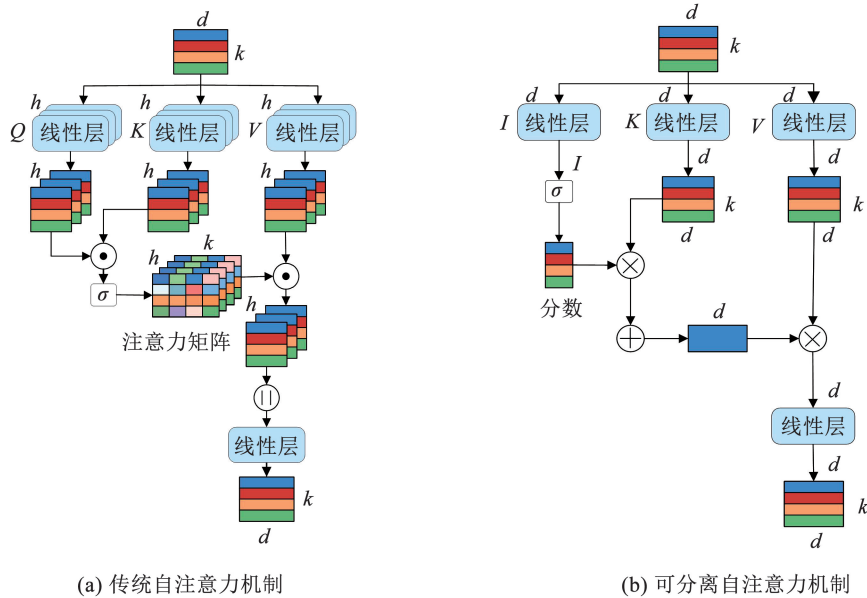


图 2 注意力机制结构图对比

Fig. 2 Comparison of structure diagrams for attention mechanisms

适应上下文聚焦机制。具体而言, SSA 首先针对潜在关键 token 计算其与输入 token 间的上下文相关性得分, 并基于该得分对输入 token 进行动态重加权调整, 最终生成一个全局上下文感知的特征向量。相较于 MHA, SSA 的计算过程更加紧凑, 能够有效降低计算开销, 同时更好地捕获长期依赖关系与全局信息。

2.2 基于两阶段解耦与多教师蒸馏的电力系统主导失稳模式识别框架

该模型采用两阶段解耦的训练框架, 其整体架构如图 3 所示。由图 3 可以看出: 在第 1 阶段, 通过实例采样策略并行训练一组具有差异性的教师模型, 这些模型借助数据增强技术学习具有泛化能力的特征表示。第 2 阶段采用类平衡采样策略训练学生模型, 使模型能够重点关注样本量较少的类别。值得注意的是, 教师模型和学生模型的训练过程完全独立, 但在第 2 阶段通过特征层面的知识蒸馏技术, 学生模型能够有效继承教师模型的特征表示, 并在此基础上进行进一步优化。这种直接在特征层面进行知识传递的蒸馏方式, 避免了教师模型在多数类样本上的偏差对分类器的影响, 从而显著提升了模型在少数类样本上的分类性能。这种解耦式两阶段训练策略具有以下优势: 1) 实现了训练过程的完全解耦, 使第 1 阶段可以专注于构建多个互补的教师模型; 2) 允许第 2 阶段从零开始训练全新的特征提取器。这种设计既增强了第 1 阶段通过模型集成改进特征表示的能力, 又为第 2 阶段提供了通用的蒸馏知识基础。

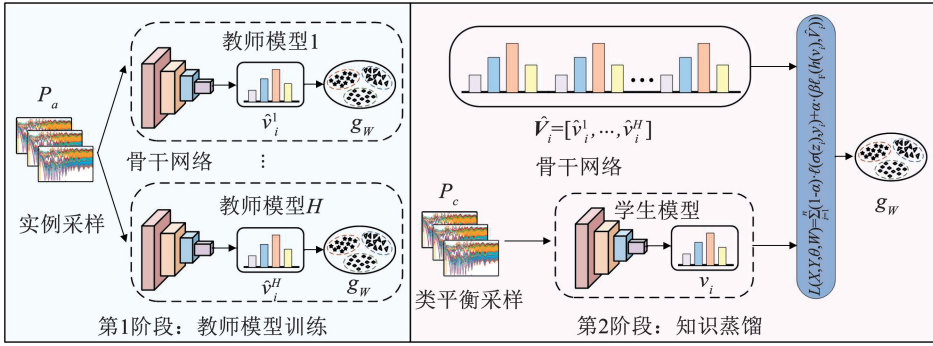


图3 主导失稳模式识别框架

Fig. 3 Recognition framework of DIM

该模型以电力系统生成的暂态特征数据作为输入,输出各类别的置信度分数。模型架构包含特征提取器和分类器两大核心模块,其中分类器采用全连接结构实现。具体而言,令 $z_i = g_w(v_i) \in \mathbf{R}^b$ 表示输出的类置信度分数,分类器 g_w 采用余弦分类器设计。在分类阶段,模型会对特征描述向量和分类器权重向量预先进行归一化处理,这一设计能够有效均衡不同类别间的距离度量,提升分类的公平性。

2.3 基于两阶段解耦与多教师蒸馏的电力系统主导失稳模式识别流程

电力系统主导失稳模式的识别流程如图4所示,主要包括样本生成、数据处理、模型训练和在线识别4个关键环节,最终为电网安全控制提供决策支持。

1) 样本生成。基于 PSASP 电力系统仿真平台,

通过调整潮流水平、负荷电动机比例、故障线路、故障位置,以及故障持续时间等关键参数,构建覆盖多种运行工况的仿真数据集。通过参数组合优化确保样本在失稳模式类别间的均衡分布。

2) 数据处理。采用专家知识对仿真样本进行失稳模式标注^[7]。为消除特征量纲差异的影响,对所有特征数据进行标准化处理,确保各特征具有相同的数值尺度。

3) 模型训练。将预处理后的样本数据输入所提模型进行训练,最终保存性能最优的模型参数。

4) 在线辨识。当电网发生故障时,实时采集 PMU 量测数据,经标准化处理后输入训练好的模型,输出主导失稳模式的识别结果。该结果将作为切机、切负荷等紧急控制策略的决策依据。

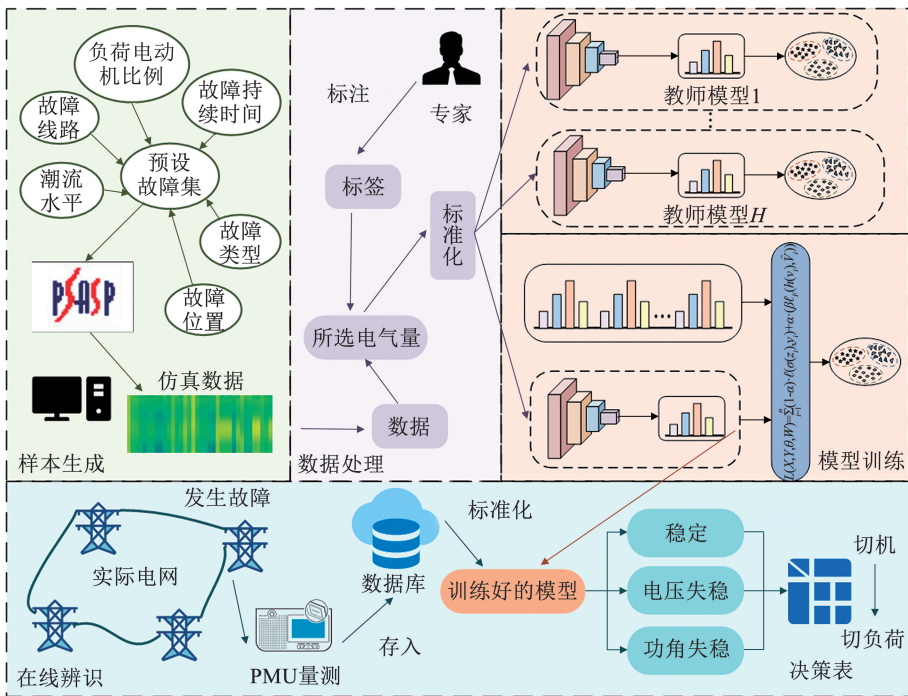


图4 主导失稳模式识别流程

Fig. 4 Recognition process of DIM

3 实验验证

3.1 实验设置

本文采用中国电力科学研究院开发的 PSASP 专业电力系统仿真软件进行数据采集。实验数据来源于 CEPRI-36 节点系统算例,该系统的拓扑结构如图 5 所示。

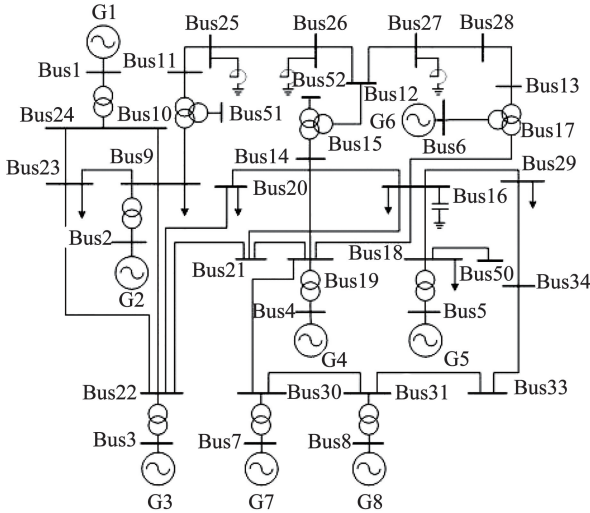


图 5 CEPRI-36 节点系统拓扑图

Fig. 5 Topology diagram of CEPRI-36 node system

选取电力系统的节点电压幅值和发电机功角作为关键特征输入,其数学表达式如下:

$$u = \begin{bmatrix} u_{1,1} & u_{1,2} & \cdots & u_{1,s} \\ u_{2,1} & u_{2,2} & \cdots & u_{2,s} \\ \vdots & \vdots & & \vdots \\ u_{t,1} & u_{t,1} & \cdots & u_{t,s} \end{bmatrix} \quad (7)$$

$$\delta = \begin{bmatrix} \delta_{1,1} & \delta_{1,2} & \cdots & \delta_{1,m} \\ \delta_{2,1} & \delta_{2,2} & \cdots & \delta_{2,m} \\ \vdots & \vdots & & \vdots \\ \delta_{t,1} & \delta_{t,1} & \cdots & \delta_{t,m} \end{bmatrix} \quad (8)$$

式中: $u_{t,s}$ 、 $\delta_{t,m}$ 分别为第 t 个采样时刻、第 S 条母线的电压,以及第 m 台发电机的功角值。

考虑到电压幅值与功角数据在量纲和数值范围上存在显著差异,为避免这种差异性对模型训练造成偏差,在特征输入前采用 z-score 标准化方法对数据进行预处理,通过对每个特征维度进行零均值化和单位方差化处理,确保不同的暂态特征数据具有可比的数据尺度,从而提高模型学习的训练效果。

采用复合负荷模型来模拟实际电网的负荷特性,具体由恒阻抗静态负荷和感应电动机动态负荷组成,其中感应电动机的比例设置为可调参数以模拟不同负荷特性。为构建全面的样本数据集,研究通过调整系统潮流水平、发电机出力、负荷增长方式等关键参数,按照如表 1 所示方案,每次仿真仅在单条线路的指定位置设置故障,其余线路无扰动且每 1/2 周波采样一次,共生成 9 750 个样本。经详细分析,数据集包含 4 069 个稳定样本、4 379 个电压失稳样本,以及 1 302 个功角失稳样本,3 类样本的比例分别为 41.7%、44.9%、13.4%,较好地覆盖了电力系统可能出现的各种暂态稳定状态。

使用 Python 构建深度学习模型,前馈神经网络的神经元个数为 256,激活函数为 ReLU 函数,batch_size 为 32,epoch 为 100,优化器采用 Adam,学习率为 0.000 1。采用分层抽样方法,将各类暂态特征数据的 10% 作为测试集进行模型测试,确保各类暂态失稳模式在测试集中占比与原始数据分布一致。

表 1 样本生成方案

Tab. 1 Sample generation scheme

条件	测试系统	潮流水平/%	负荷电动机比例/%	故障线路	故障位置/%	故障持续时间/s	故障类型	仿真时间/s
参数	CEPRI-36 节点系统算例	90、100、110	50、60、70、80、90	所有交流线路	5、20、50、80、95	0.10、0.15、0.20、0.25、0.30	三相短路	10
类别	1	3	5	26	5	5	1	1

3.2 关键模型参数分析与选择

采用卷积神经网络 (convolutional neural networks, CNN) 评估平衡时间序列数据集不同时间窗口长度的影响。如图 6 所示,由于包含的时序信息不足,模型难以充分提取有效特征,过大则引入冗

余信息并增加计算负担。经对比分析,确定 3 s 为最优窗口长度,此时模型分类准确率达 98.72%,这一参数设置实现了特征提取的充分性与计算效率之间的平衡。




图 6 窗口选择结果

Fig. 6 Window selection results

对 Transformer 模型中注意力头数这一关键超参数进行了系统性评估。结果如图 7 所示,通过控制变量实验发现:当注意力头数小于 8 时,模型性能随着头数增加而显著提升,这表明多头注意力机制能有效捕捉时间序列中不同维度的特征表示;然而当注意力头数超过 8 时,模型在测试集上的准确率明显下降,同时训练时长近线性增长,这一现象可能源于过多的注意力头会导致模型容量过大,容易在有限训练数据上产生过拟合以及计算资源的无效消耗。基于实验分析,最终确定 8 个注意力头为最优配置,该参数设置能在模型性能与计算效率之间取得最佳平衡。




图 7 注意力头数选择结果

Fig. 7 Selection results of number of attention heads

本文通过系统性实验深入探究了多教师模型数量 (H)、特征蒸馏损失项的缩放因子 (β), 以及蒸馏权重 (α) 对模型性能精度的影响机制 (表 2), 观察到以下现象: 模型性能与教师数量呈正相关, 从 $H=1$ 到 $H=4$ 平均准确率提升 0.27%, 当 $H=4$ 时达到性能峰值, 平均准确率为 97.618%, 此后增加教师数量模型性能递减。在 $\alpha=0.7$ 和 $\beta=100.0$ 的最优组合下, 模型获得最佳训练效果。

表 2 不同参数下模型准确率结果

教师网络个数	参数	准确率/%				
		$\beta=0.1$	$\beta=1.0$	$\beta=10.0$	$\beta=100.0$	$\beta=200.0$
$H=1$	$\alpha=0.1$	96.84	96.75	95.38	97.44	97.86
	$\alpha=0.3$	97.86	97.52	97.44	97.18	97.86
	$\alpha=0.5$	97.86	97.26	97.61	97.52	97.26
	$\alpha=0.7$	97.86	98.03	97.69	97.44	97.35
	$\alpha=0.9$	98.03	97.44	97.78	97.26	95.21
$H=2$	$\alpha=0.1$	97.52	97.78	97.95	97.95	97.78
	$\alpha=0.3$	97.61	97.86	97.61	96.41	97.26
	$\alpha=0.5$	97.69	97.86	98.29	97.95	97.18
	$\alpha=0.7$	97.61	96.84	97.09	97.34	97.61
	$\alpha=0.9$	97.58	97.01	97.95	97.52	95.38
$H=3$	$\alpha=0.1$	97.44	97.52	98.03	97.69	96.25
	$\alpha=0.3$	98.21	97.86	98.12	97.69	97.78
	$\alpha=0.5$	97.95	97.78	98.03	97.95	97.26
	$\alpha=0.7$	97.95	96.75	98.21	98.38	97.26
	$\alpha=0.9$	98.03	97.95	94.27	95.98	96.75
$H=4$	$\alpha=0.1$	98.03	97.61	97.62	97.61	97.52
	$\alpha=0.3$	98.03	98.21	97.61	98.21	97.52
	$\alpha=0.5$	97.61	96.41	97.69	97.44	97.86
	$\alpha=0.7$	96.32	98.03	97.86	98.61	97.95
	$\alpha=0.9$	97.78	98.21	97.86	96.67	96.24
$H=5$	$\alpha=0.1$	98.03	97.44	97.61	97.26	97.26
	$\alpha=0.3$	97.69	97.69	97.35	98.21	98.21
	$\alpha=0.5$	97.52	98.03	97.35	97.95	97.78
	$\alpha=0.7$	97.78	96.15	97.69	96.84	97.18
	$\alpha=0.9$	97.69	97.52	98.38	97.09	95.21

综上所述可得, 当窗口长度选择为 3 s, 注意力头数为 8, 教师模型个数 $H=4$, $\beta=100.0$, $\alpha=0.7$ 时的超参数组合达到性能最优, 证实了合理设计教师集成规模与参数协同优化对提升蒸馏效果的关键作用, 这些经过严格验证的配置为后续研究提供了可靠的基准参数体系。

3.3 消融实验

本文采用两阶段框架设计, 为验证各阶段的有效性, 进行了系统的消融实验分析, 如图 8 所示。实验设置包含以下 3 种配置: 1) 完整框架; 2) 仅第 1 阶段; 3) 仅第 2 阶段。实验结果表明, 虽然仅单个阶段模型在整体准确率上表现良好均超过 95% (表 3)。

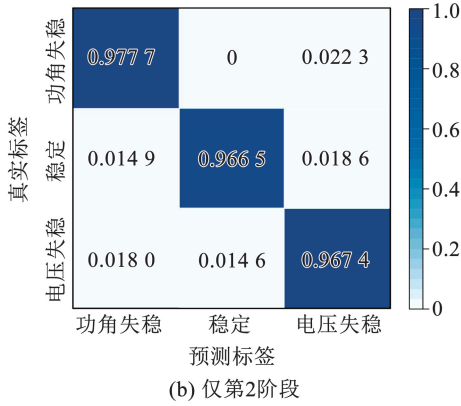
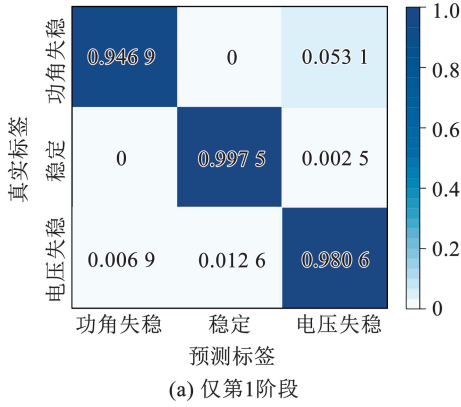


图 8 消融实验混淆矩阵

Fig. 8 Confusion matrix of ablation experiment

表 3 消融实验结果

Tab. 3 Results of ablation experiment

方法	准确率/%	精确率/%	召回率/%	F ₁ 分数/%
TSDM	98.61	98.61	98.61	98.61
仅第 1 阶段	97.35	97.45	97.35	97.36
仅第 2 阶段	97.61	97.69	97.61	97.61

由图 8 可以看出,两个阶段的分类性能存在明显的互补特性。第 1 阶段模型对多数类样本(稳定和电压失稳)具有优异的识别能力,准确率分别达到 99.75% 和 98.06%,但对少数类样本(功角失稳)的误判率较高达到 5.31%;相反,第 2 阶段模型在少数类识别上表现突出,但对多数类样本的误判率有所增加。这种分类偏差的差异性验证了本文提出的两阶段协同优化策略的必要性,通过特征级知识蒸馏和预测结果融合,最终模型实现了对各类样本的均衡识别。

3.4 对比实验

为了系统验证本文提出模型的性能优势,本文对特征蒸馏和分类蒸馏方法进行了全面的对比实验分析。实验设置了分类蒸馏温度系数 $T \in \{0.1, 1.0, 5.0, 10.0, 100.0, 200.0\}$ 多个梯度值进行对比测试。如图 9 所示,在不同温度参数配置下,本文模型在准确率、精确率等各项性能指标上均展现出稳

定的优势。特别地,当 $T = 100.0$ 时,分类蒸馏方法取得了最佳表现,其准确率达到 98.29%,但仍比本文模型低 0.32 个百分点;在精确率指标上,分类蒸馏为 98.33%,较本文模型低 0.29 个百分点。这一结果表明,即使在分类蒸馏最优参数配置下,本文方法仍能保持稳定的性能优势。

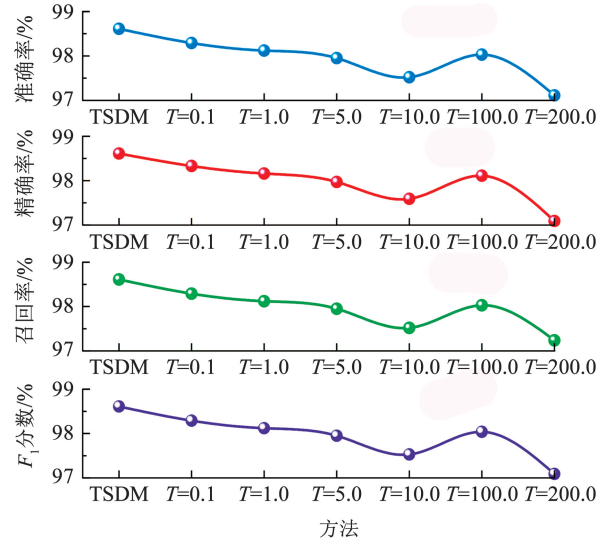


图 9 特征蒸馏与分类蒸馏对比结果

Fig. 9 Comparison results between feature distillation and classification distillation

为深入评估本文所提出模型的性能优势,本文基于文献[26]中的基准模型架构开展了系统的对比实验。具体而言,选取文献[26]中的 CNN、GCN 和 GRU 模型分别作为本文模型的骨干网络,构建了 3 个对比实验模型,并分别命名为 N2、N3 和 N4,为保持对比的完整性,将文献[26]的原始模型作为参照基准(记为 N5)。同时进行与使用传统 Transformer 的框架进行对比实验,并将其命名为 N1。如图 10 所示。

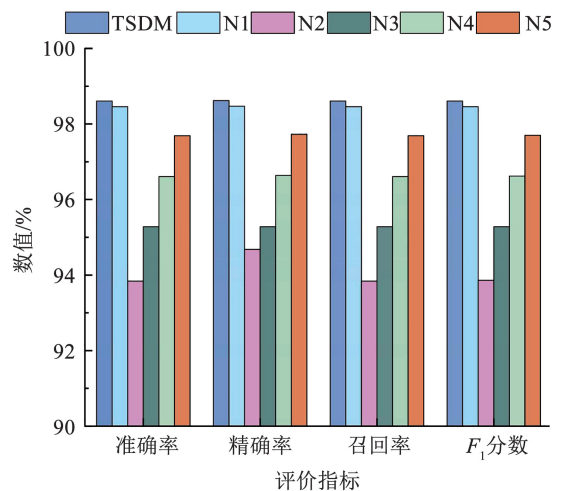


图 10 各方法对比结果

Fig. 10 Comparison results of various methods

实验结果表明,对比模型准确率分别为 98.46%、93.84%、95.28%、96.61% 和 97.69%, 本文模型在所有对比方案中展现出显著优势取得了 98.61% 的准确率,较最优对比方案提升了 0.15 个百分点。这一性能优势主要源于该模型采用的 Transformer 架构通过嵌入可分离注意力机制,能够有效建模长距离依赖关系,并保持信息的完整性,从而获得了更优的性能表现。

通过对各模型的计算复杂度及训练时间进行对比(表 4)分析可以发现,虽然 TSDM 模型在训练时间上比其他模型略长,但在模型参数量、计算量,以及内存占用方面,TSDM 模型展现出显著优势。尽管 GRU 骨干网络模型在计算效率和训练速度上表现更优,但其识别准确率与 TSDM 模型相比明显降低。

表 4 模型计算复杂度与训练效率对比

Tab. 4 Comparison of computational complexity and training efficiency for models

方法	准确率/%	参数量/M	计算量/ ($10^9 s^{-1}$)	占用内存/MB	训练时间/s
TSDM	98.61	0.66	0.47	67.79	1 241.29
骨干网络为传统	98.46	2.08	0.94	130.29	2 007.83
Transformer 骨干网络为 CNN	93.84	0.78	1.44	96.43	726.94
骨干网络为 GCN	95.28	1.22	1 313.87	97.96	17 603.20
骨干网络为 GRU	96.61	0.48	0.24	48.15	128.52
文献[26]	97.69	0.73	0.52	71.86	568.14

选择性能最好的分类蒸馏模型与对比模型进行训练过程的可视化分析,结果如图 11 所示。从图 11 可以看出,当训练进行到第 9 个轮次时,其损失值(0.46)较骨干网络为 GCN 的对比模型(0.55)降低 0.09,尽管略高于传统分类蒸馏方法,但其已达到稳定收敛状态。与此同时,所提模型的准确率曲线呈现快速上升趋势,并在第 20 轮次达到稳定状态,最终准确率为 99.54%。较最优对比模型提升 0.28%。

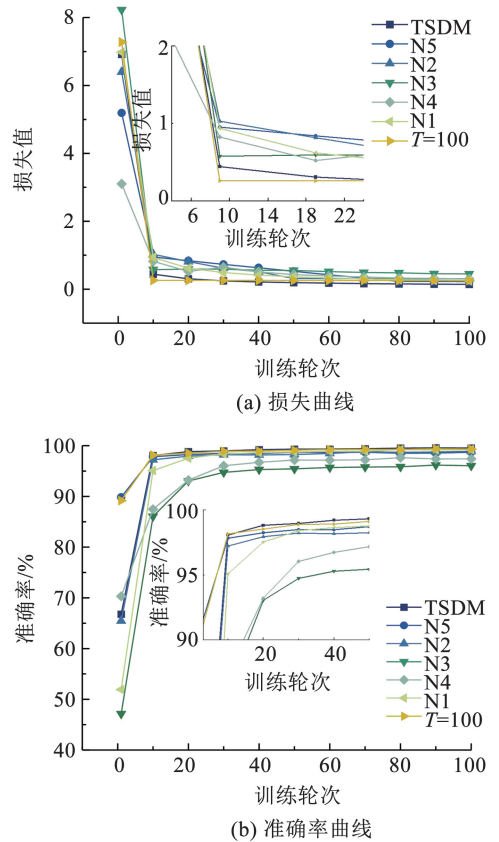


图 11 训练损失和准确率曲线

Fig. 11 Curves of training loss and accuracy

混淆矩阵如图 12 所示,大多数样本都能被准确分类,只有少数样本存在误判现象。值得注意的是,所提方法的混淆矩阵中,不稳定样本被判定为稳定样本的概率为 0,说明该模型能够确保不稳定样本被及时识别为不稳定样本,避免了遗漏可能导致系统危机的错误判断,但也出现了类型错误的判定,可能导致后续控制或者应对措施不够精确,影响电力系统的稳定和响应效率。为了更直观地评估模型的性能,采用 *t*-SNE 技术对测试样本的深层特征进行了降维可视化分析。由图 12 可以看出,采用分类蒸馏和特征蒸馏策略的 TSDM 框架展现出显著类别可分性,不同类别的样本形成了界限分明的聚类簇,且类间重叠区域明显减少。相比之下,对比模型的可视化结果呈现出较为分散的样本分布,各类别边界模糊,聚类效果明显逊色于所提出的方法。

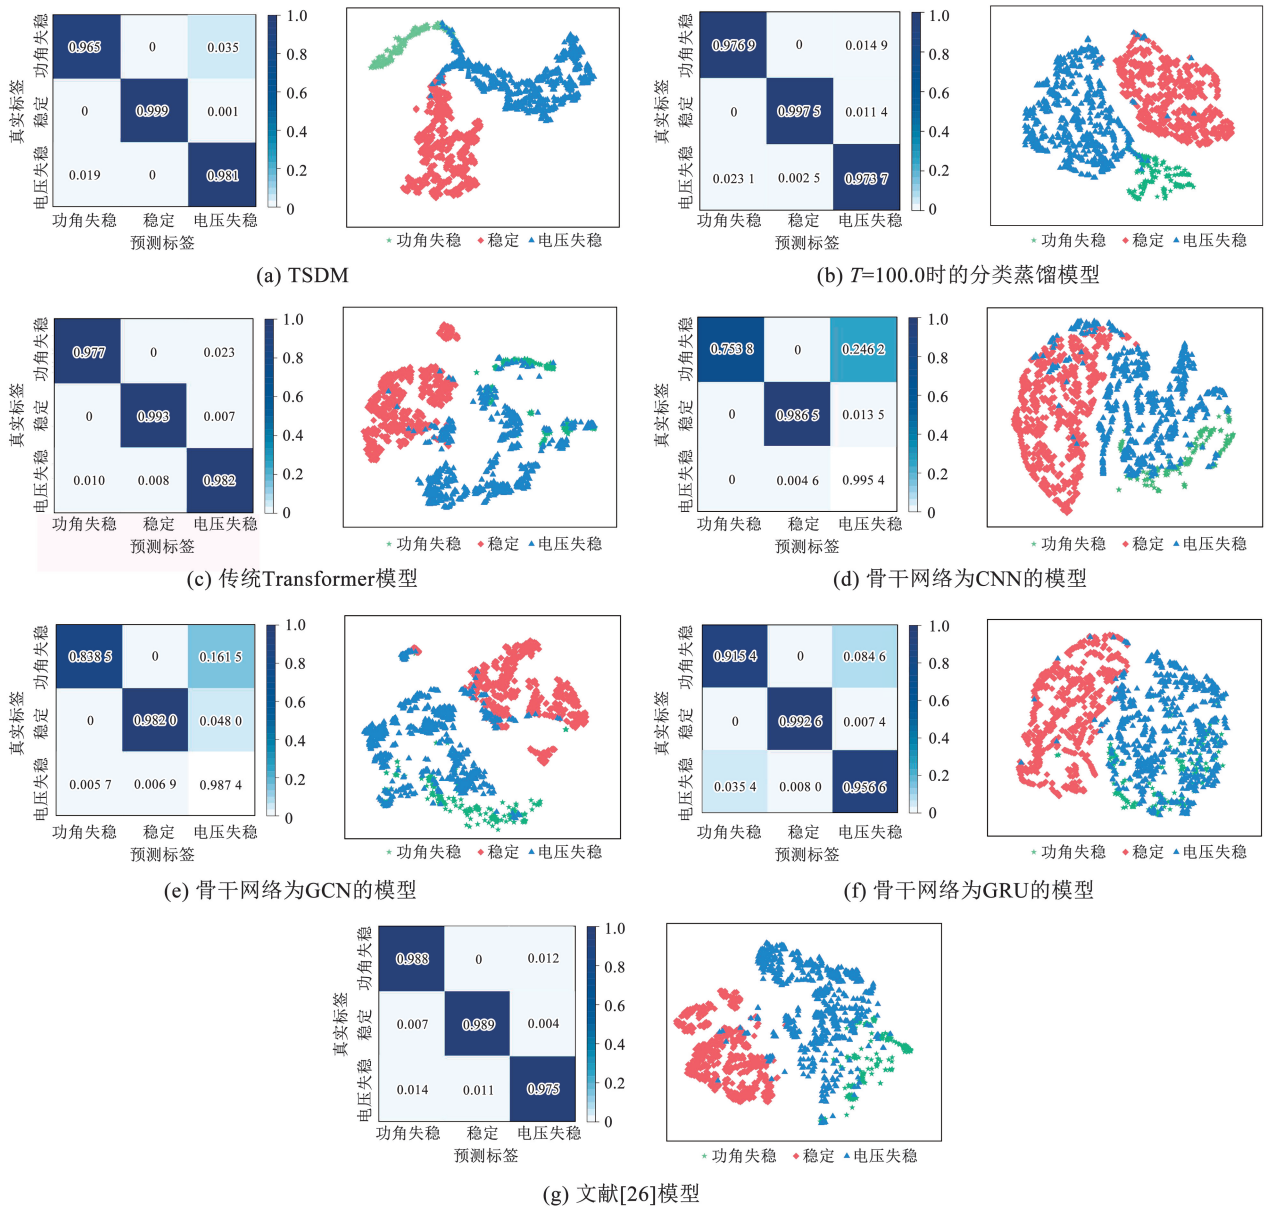


图 12 对比模型的混淆矩阵和 t -SNE 可视化结果

Fig. 12 Confusion matrix and t -SNE visualization results of comparison models

4 结 论

1) TSDM 模型在电力系统主导失稳模式识别中表现优异, 整体准确率可达到 98.61%。特别地, 对少数类识别准确率可达到 96.50%。

2) 采用实例采样与类平衡采样的优化策略, 将各类别识别准确率差异控制在 3% 以内。通过特征蒸馏技术显著提升模型对少数类样本的特征敏感性, 在保持最高整体准确率的同时, 实现了最优的类别均衡性表现。

3) 本文提出的电力系统暂态稳定智能识别方法, 显著提升了不平衡样本场景下的失稳模式识别性能, 尤其改善了以往方法对少数类故障的识别能力。但本文算法主要针对静态不平衡数据设计, 面

对动态变化数据时需反复调整, 缺乏持续适应能力。后续研究将构建动态适应框架, 通过增量表征更新和自适应分类器优化, 提升算法对时变数据分布的适应能力。

参考文献

[1] TIAN Jinfang, YU Longguang, XUE Rui, et al. Global low-carbon energy transition in the post-COVID-19 era [J]. Applied Energy, 2022, 307: 118205. DOI:10.1016/j.apenergy.2021.118205

[2] LIU Jizhe, ZHANG Yuchen, MENG Ke, et al. Real-time emergency load shedding for power system transient stability control: A risk-averse deep learning method [J]. Applied Energy, 2022, 307: 118221. DOI:10.1016/j.apenergy.2021.118221

[3] HU Ze, YAO Wei, SHI Zhongtuo, et al. Intelligent and rapid event-based load shedding pre-determination for large-scale power systems: knowledge-enhanced parallel branching dueling Q-network approach [J]. Applied Energy, 2023, 347: 121468. DOI:10.1016/j.apenergy.

2023. 121468
- [4] ZHOU Hongyu, YAO Wei, SUN Kangyi, et al. Characteristic investigation and overvoltage suppression of MMC-HVDC integrated offshore wind farms under onshore valve-side SPG fault [J]. IEEE Transactions on Power Systems, 2024, 39(1): 1346. DOI: 10.1109/TPWRS.2023.3236095
- [5] HATZIARGYRIOU N, MILANOVIC J, RAHMANN C, et al. Definition and classification of power system stability-revisited & extended [J]. IEEE Transactions on Power Systems, 2021, 36(4): 3271. DOI: 10.1109/TPWRS.2020.3041774
- [6] VOURNAS C D, SAUER P W, PAI M A. Relationships between voltage and angle stability of power systems [J]. International Journal of Electrical Power & Energy Systems, 1996, 18(8): 493. DOI: 10.1016/0142-0615(96)00009-9
- [7] 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
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. DOI: 10.13334/j.0258-8013.pcsee.211132
- [8] SHI Zhongtuo, YAO Wei, TANG Yong, et al. Bidirectional active transfer learning for adaptive power system stability assessment and dominant instability mode identification [J]. IEEE Transactions on Power Systems, 2023, 38(6): 5128. DOI: 10.1109/TPWRS.2022.3220955
- [9] ZHANG Runfeng, YAO Wei, SHI Zhongtuo, et al. Towards multi-scenario power system stability analysis: an unsupervised transfer learning method combining DGAT and data augmentation [J]. IEEE Transactions on Power Systems, 2023, 38(6): 5367. DOI: 10.1109/TPWRS.2022.3220569
- [10] 胡智超, 徐翔湛, 刘立坤, 等. 基于上下文生成对抗网络的时间序列异常检测方法 [J]. 哈尔滨工业大学学报, 2024, 56(5): 1
HU Zhichao, YU Xiangzhan, LIU Likun, et al. A time series anomaly detection method based on contextual generative adversarial network [J]. Journal of Harbin Institute of Technology, 2024, 56(5): 1. DOI: 10.11918/202212029
- [11] 李艳波, 尹轲, 陈俊硕, 等. 结合改进残差网络和Bi-LSTM的短期电力负荷预测 [J]. 哈尔滨工业大学学报, 2023, 55(8): 79
LI Yanbo, YIN Pu, CHEN Junshuo, et al. Short-term power load forecasting based on combination of residual network and Bi-LSTM [J]. Journal of Harbin Institute of Technology, 2023, 55(8): 79. DOI: 10.11918/202208110
- [12] 邵美阳, 吴俊勇, 李宝琴, 等. 基于两阶段集成深度置信网络的电力系统暂态稳定评估 [J]. 电网技术, 2020, 44(5): 1776
SHAO Meiyang, WU Junyong, LI Baoqin, et al. Transient stability assessment of power system based on two-stage ensemble deep belief network [J]. Power System Technology, 2020, 44(5): 1776. DOI: 10.13335/j.1000-3673.pst.2019.1770
- [13] REN Chao, XU Yan, ZHANG Rui. An interpretable deep learning method for power system transient stability assessment via tree regularization [J]. IEEE Transactions on Power Systems, 2022, 37(5): 3359. DOI: 10.1109/TPWRS.2021.3133611
- [14] SHI Zhongtuo, YAO Wei, ZENG Linggang, et al. Convolutional neural network-based power system transient stability assessment and instability mode prediction [J]. Applied Energy, 2020, 263: 114586. DOI: 10.1016/j.apenergy.2020.114586
- [15] ZHAN Xianwen, HAN Song, RONG Na, et al. A hybrid transfer learning method for transient stability prediction considering sample imbalance [J]. Applied Energy, 2023, 333: 120573. DOI: 10.1016/j.apenergy.2022.120573
- [16] LI Yang, ZHANG Meng, CHEN Chen. A deep-learning intelligent system incorporating data augmentation for short-term voltage stability assessment of power systems [J]. Applied Energy, 2022, 308: 118347. DOI: 10.1016/j.apenergy.2021.118347
- [17] ZHU Lipeng, HILL D J, LU Chao. Intelligent short-term voltage stability assessment via spatial attention rectified RNN learning [J]. IEEE Transactions on Industrial Informatics, 2021, 17(10): 7005. DOI: 10.1109/TII.2020.3041300
- [18] 郑乐, 刘思远, 周小添, 等. 面向电力系统暂态稳定性评估的深度学习方法智能增强方法 [J]. 电网技术, 2025, 49(7): 2649
ZHENG Le, LIU Siyuan, ZHOU Xiaotian, et al. Model enhancement for deep learning based transient stability assessment models [J]. Power System Technology, 2025, 49(7): 2649. DOI: 10.13335/j.1000-3673.pst.2024.0767
- [19] 李雨婷, 刘俊, 刘嘉诚, 等. 基于去噪扩散概率模型不平衡样本增强的暂态稳定评估 [J]. 电力系统自动化, 2024, 48(21): 148
LIU Yuting, LIU Jun, LIU Jiacheng, et al. Transient stability assessment based on imbalanced sample enhancement of denoising diffusion probabilistic model [J]. Automation of Electric Power Systems, 2024, 48(21): 148. DOI: 10.7500/AEPS20240415007
- [20] 李楠, 李保罗, 朱建华, 等. 计及样本不平衡与重叠的暂态稳定评估方法 [J]. 电力系统自动化, 2020, 44(21): 64
LI Nan, LI Baoluo, ZHU Jianhua, et al. Transient stability assessment method considering sample imbalance and overlap [J]. Automation of Electric Power Systems, 2020, 44(21): 64. DOI: 10.7500/AEPS20200114005
- [21] 李嘉敏, 杨红英, 闫莉萍, 等. 样本不平衡情况下的电力系统暂态稳定集成评估方法 [J]. 电力系统自动化, 2021, 45(10): 34
LI Jiamin, YANG Hongying, YAN Liping, et al. Integrated assessment method for transient stability of power system under sample imbalance [J]. Automation of Electric Power Systems, 2021, 45(10): 34. DOI: 10.7500/AEPS20200309001
- [22] 马彬喻, 杨军, 彭晓涛, 等. 基于改进CVAE-GAN的电力系统暂态稳定评估样本增强方法 [J]. 电力自动化设备, 2025, 45(9): 216
MA Binyu, YANG Jun, PENG Xiaotao, et al. Sample augment method for power system transient stability assessment based on improved CVAE-GAN [J]. Electric Power Automation Equipment, 2025, 45(9): 216. DOI: 10.16081/j.epae.202504023
- [23] 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
XIE Zhijun, ZHANG Dongxia, HAN Xiaqing, 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. DOI: 10.13335/j.1000-3673.pst.2023.1482
- [24] 肖龙, 张靖, 何宇, 等. 基于时间卷积和自适应图卷积网络的电力系统暂态稳定评估 [J]. 电网技术, 2025, 49(11): 4580
XIAO Long, ZHANG Jing, HE Yu, et al. Power system transient stability assessment based on temporal convolution and adaptive graph convolution network [J]. Power System Technology, 2025, 49(11): 4580. DOI: 10.13335/j.1000-3673.pst.2024.1724
- [25] 赵小强, 何嘉琦. 基于最大安全近邻与局部密度的自适应过采样方法 [J]. 电子与信息学报, 2025, 47(4): 1140
ZHAO Xiaoqiang, HE Jiaqi. Adaptive oversampling method based on maximum safe nearest neighbor and local density [J]. Journal of Electronics & Information Technology, 2025, 47(4): 1140. DOI: 10.11999/JEIT240441
- [26] WANG Changjiang, ZHANG Qianlong, ZHOU Qinyong, et al. Power system dominant instability mode identification based on improved multi-head attention and CNN [C]//2024 IEEE 7th International Electrical and Energy Conference (CIEEC). Harbin: IEEE, 2024: 2218. DOI: 10.1109/CIEEC60922.2024.10583215