

华北电力大学

学术博士学位论文

基于深度学习的电力系统暂态稳定评估

**Power System Transient Stability Assessment
Based on Deep Learning**

房佳姝

2024 年 5 月

国内图书分类号：TM712
国际图书分类号：621.3

学校代码：10079
密 级：公开

学术博士学位论文

基于深度学习的电力系统暂态稳定评估

博 士 研 究 生：房佳姝

导 师：刘崇茹教授

申 请 学 位：工学博士

学 科：电气工程

专 业：电气工程

所 在 学 院：电气与工程学院

答 辩 日 期：2024 年 5 月

授予学位单位：华北电力大学

Classified Index: TM712

U.D.C: 621.3

Dissertation for the Academic Doctoral Degree

**Power System Transient Stability Assessment
Based on Deep Learning**

Candidate:	Jiashu Fang
Supervisor:	Prof. Chongru Liu
Academic Degree Applied for:	Doctor of Engineering
Subject:	Electrical Engineering
Speciality:	Electrical Engineering
School:	School of Electrical and Electronic Engineering
Date of Defense:	May, 2024
Degree-Conferring-Institution:	North China Electric Power University

摘 要

随着近年来电力电子设备的大规模应用和特高压交直流互联等新兴技术的高速发展，电力系统的运行方式更加多样、潜在故障点增多，给电力系统暂态稳定带来了新的挑战。本研究基于深度学习的数据驱动方法对电力系统暂态稳定评估问题展开深入研究，提出关键数据生成方法、缺失数据重建方法，以及可解释性增强的暂稳评估算法，最终旨在提高数据驱动暂稳评估的准确度、可信性和现场实用性，主要研究工作总结如下：

首先，针对离线集合中临界场景匮乏导致的暂稳评估模型对暂稳边界刻画能力不足的问题，提出了一种能够充分刻画暂态稳定边界的样本生成方法。该方法通过构建考虑样本临界度的损失函数，并建立无监督算法中的有监督结构，引导生成样本向暂态稳定边界偏移。本文通过生成边界样本，增强暂态稳定评估模型对稳定知识的学习和提取能力，提高模型训练效率，并提升模型性能。针对不同的应用场景，本文分别建立了能够生成安全域下的临界样本和稳定域下的临界失稳样本的样本生成算法，为数据驱动的暂态稳定模型的实际应用提供了大规模离线数据基础。

其次，针对数据不完整导致的暂态稳定评估算法在线应用准确率下降的问题，提出了适用于不完整训练集的高细粒度数据重建算法。通过建立细粒度更高的算法结构，以及构建引入数值约束的算法损失函数，提升了模型对电网时空依赖的提取能力和重建准确性。实验结果显示，在随机数据缺失和 PMU 故障场景下，相比现有方法，所提出的模型具有更高的重建准确率。同时，本文还建立了可解释的重建算法，使模型能够自主识别并提取有价值信息，进一步增强了在实际应用中的可信度。旨在重建缺失数据，以维持暂态稳定评估在线应用时的准确性。

再次，针对现有的暂态评估模型缺乏可解释性且难以被信任的问题，本文提出了基于自注意力编码器的暂态稳定多阶段预测模型。该方法具有良好的可解释性，能够揭示深层网络内部参数对暂态重要特征的自适应偏移和聚焦，以及不同特征对于决策的贡献度。通过展示模型内部的注意力权重，验证了深层网络内部参数分布符合实际物理机制，说明该方法可解释性被增强，且具有更高的准确性和鲁棒性。

最后，针对现有暂稳评估模型需要准确的故障清除时刻信息，因此受电气设备间时钟误差和继保信号影响的问题，本文提出了基于 Vision-Transformer 网络的在线暂稳监测系统，旨在实现暂态稳定性评估和失稳发电机组的识别。该系统根据当前操作点提供暂态状态，无需获知准确的故障清除时刻，同时适

用于继电器失效场景。实验结果表明，所提出的方法在准确性和鲁棒性方面优于现有方法。此外，为了得到不同决策保守度下的失稳判定阈值，本文提出了一种自适应调整的失稳阈值设定方法，以进一步增加算法的适用性。

关键词：暂态稳定评估；深度学习；样本生成；人工智能；可解释性

Abstract

With the rapid development of large-scale application of power electronic devices in recent years and emerging technologies such as ultra-high voltage AC/DC interconnection, the operation of the power system has become more diverse, with an increasing number of potential fault points, posing new challenges to transient stability. This thesis conducts in-depth research on the transient stability assessment of power systems using data-driven methods based on deep learning. It proposes key data generation methods, data reconstruction methods for missing data, and interpretable transient stability assessment algorithms. The ultimate goal is to improve the accuracy, reliability, and practicality of data-driven transient stability assessment. The main research activities are summarized as follows:

Firstly, to address the challenge of inadequate characterization of transient stability boundaries by transient stability assessment models and the low efficiency of model training due to the scarcity of critical scenarios in offline datasets, this thesis proposes a sample generation method that fully captures transient stability boundaries. This method constructs a loss function considering the criticality of samples and establishes a supervised structure within unsupervised algorithms to guide the generation of samples towards transient stability boundaries. By generating boundary samples, this thesis improves the transient stability assessment model's learning and extraction capabilities regarding stability knowledge, enhances the efficiency of model training, and improves the model performance. For different application scenarios, this thesis develops sample generation algorithms capable of producing critical samples in security domains and critical unstable samples in stability domains, providing a large-scale offline data foundation for data-driven transient stability models in practical applications.

Secondly, to address the issue of decreased accuracy in online applications of transient stability assessment algorithms due to incomplete data, this thesis proposes a high-resolution data reconstruction algorithm suitable for incomplete training sets. By establishing a finer-grained algorithmic structure and constructing an algorithmic loss function incorporating value constraints, the model's ability to extract temporal and spatial dependencies of the power grid and its reconstruction accuracy are improved. Experimental results demonstrate that, compared to existing methods, the proposed model achieves higher reconstruction accuracy under scenarios of random data loss and PMU failures. Additionally, this thesis establishes an interpretable reconstruction algorithm,

enabling the model to autonomously identify and extract valuable information, thereby further enhancing its credibility in practical applications. This research aims to reconstruct missing field data, providing a preprocessing data reconstruction step for feeding online data into transient stability assessment models, thereby maintaining accuracy in online transient stability assessment applications.

Furthermore, to address the issue of the lack of interpretability and trustworthiness in existing transient assessment models, this thesis proposes a multi-stage prediction model for transient stability based on self-attention encoders. Notably, this method offers enhanced interpretability by revealing the adaptively focus of internal parameters within deep networks on crucial transient features, as well as the contribution of different features to decision-making. Furthermore, by showcasing the attention weights within the model, the distribution of internal parameters in deep networks is validated to align with actual physical mechanisms, thereby ensuring heightened interpretability alongside improved accuracy and robustness.

Finally, to address the need for precise fault clearance information in existing models, which is susceptible to clock deviations between electrical devices and relay protection signals, this thesis proposes an online transient stability monitoring system based on the Vision-Transformer network. The objective of this work is to achieve TSA and identify unstable generator generators. This method provides transient prediction based on the current operating point without relying on the accurate fault clearance moments, making it suitable for relay failure scenarios. Experimental results demonstrate that the proposed method outperforms existing approaches in terms of accuracy and robustness. Additionally, to obtain instability threshold values under different decision conservativeness levels, this study proposes an adaptive adjustment algorithm for setting instability threshold values, further enhancing the algorithm's applicability.

Keywords: Transients stability assessment, deep learning, sample generation, artificial intelligence, interpretability

目 录

第 1 章 绪论.....	1
1.1 选题背景.....	1
1.2 电力系统暂态稳定评估及其经典方法综述	2
1.2.1 时域仿真法.....	3
1.2.2 直接法.....	4
1.2.3 轨迹分析法.....	5
1.3 基于人工智能的暂态稳定方法综述	6
1.3.1 人工智能暂稳评估方法的数据库建立	7
1.3.2 人工智能暂稳评估方法的特征工程.....	8
1.3.3 人工智能暂稳评估方法的算法设计.....	10
1.4 人工智能方法在暂态稳定评估中的挑战	12
1.4.1 离线样本集合中临界样本匮乏.....	12
1.4.2 现场数据部分缺失导致模型性能下降	13
1.4.3 深度学习可解释性不足.....	14
1.5 本文研究工作.....	15
1.5.1 研究框架.....	15
1.5.2 拟解决的问题和研究思路.....	16
1.5.3 主要研究内容与章节安排.....	18
第 2 章 面向动态安全评估任务的边界样本生成方法	21
2.1 引言.....	21
2.2 基于卷积神经网络的电力系统信息提取层	22
2.3 生成对抗网络基本概述.....	27
2.3.1 判别器基本结构.....	28
2.3.2 生成器基本结构.....	28
2.4 电网安全边界数据生成方法	28
2.4.1 考虑生成数据真实性的判别器损失函数	29
2.4.2 考虑生成样本极限切除时刻的生成器损失函数	29
2.4.3 预测样本 CCT 的回归模型.....	31
2.5 算例分析.....	32
2.5.1 数据集合构建.....	32
2.5.2 CCT 回归模型结构和性能.....	33
2.5.3 边界样本生成模型结构和性能.....	34
2.6 与现有数据生成方法的对比	36
2.6.1 生成样本的真实性和临界程度.....	36

2.6.2 算法可扩展性测评与可视化:以 IEEE-9 节点系统为例	37
2.7 生成样本对 DSA 模型性能的提升	39
2.8 本章小结.....	40
第 3 章 面向暂稳评估任务的临界失稳样本生成方法	41
3.1 引言.....	41
3.2 基于生成对抗结构的失稳样本生成模型	42
3.2.1 失稳样本生成模型的总体目标函数.....	42
3.2.2 考虑生成数据真实性的判别器损失函数	42
3.2.3 考虑分布偏移的失稳样本生成器.....	42
3.3 算例分析.....	45
3.3.1 样本集数据.....	45
3.3.2 模型结构和性能.....	46
3.3.3 生成样本的真实程度分析.....	49
3.3.4 与现有数据生成方法的对比.....	50
3.4 所提数据增强算法对暂稳评估模型增强的验证和分析	51
3.5 算法可拓展性测评:以 POLISH-2383 节点系统为例.....	56
3.5.1 测试系统与数据生成.....	56
3.5.2 数值测试结果分析.....	56
3.6 本章小结.....	58
第 4 章 基于生成对抗网络的数据重建方法	59
4.1 引言.....	59
4.2 基于生成对抗机制的电网数据重建算法	60
4.2.1 电网数据重建算法基本框架.....	61
4.2.2 生成对抗模型优化过程.....	63
4.2.3 网络内部注意力可视化结构构建.....	64
4.3 算例分析.....	66
4.3.1 数据集建立.....	66
4.3.2 算法结构和性能分析.....	67
4.3.3 注意力图可视化.....	69
4.3.4 与现有方法的对比.....	70
4.4 算法可拓展性测评:NPCC 48 机 140 节点系统算例.....	72
4.4.1 测试系统与数据生成.....	72
4.4.2 数值测试结果分析.....	73
4.5 本章数据重建算法对在线 TSA 准确率的提升验证.....	74
4.6 本章小结.....	75
第 5 章 基于注意力机制的暂态稳定评估模型	76
5.1 引言.....	76
5.2 面向电气时序信息提取的 TRANSFORMER 注意力网络.....	77

5.2.1 面向电气时序的位置编码.....	77
5.2.2 面向电气特征的多头自注意力提取层	78
5.2.3 前馈神经网络.....	79
5.2.4 层归一化运算与残差连接.....	80
5.3 多阶段暂态稳定评估框架	81
5.3.1 面向暂态稳定评估问题的分类模型架构	81
5.3.2 多阶段电力系统暂稳评估流程.....	82
5.4 算例分析.....	85
5.4.1 数据集生成.....	85
5.4.2 模型性能的评估指标.....	85
5.4.3 与现有方法的对比.....	86
5.4.4 模型对电气特征的注意力分布可视化	88
5.4.5 模型面对异常特征的鲁棒性.....	91
5.4.6 模型失稳阈值分析.....	93
5.4.7 与现有多阶段暂稳方法的对比分析.....	94
5.5 算法可拓展性测评:以 POLISH-23 83 节点系统为例.....	95
5.5.1 测试系统与数据生成.....	95
5.5.2 数值测试结果分析.....	95
5.6 本章小结.....	96
第 6 章 基于注意力机制的在线暂态稳定监测模型	97
6.1 引言.....	97
6.2 基于 IT 的 TSA 分类模型和失稳机组识别模型	98
6.2.1 ViT 模型电气信息提取层	98
6.2.2 ViT 模型分类输出层.....	100
6.3 在线暂稳评估方法.....	101
6.3.1 离线训练过程.....	101
6.3.2 在线识别阶段.....	104
6.4 测试算例分析.....	106
6.4.1 数据集生成.....	106
6.4.2 模型性能.....	107
6.4.3 噪声场景下的模型性能对比.....	109
6.4.4 考虑现场数据缺失的模型性能对比.....	110
6.4.5 最优阈值设置.....	111
6.5 算法可拓展性测评:以交直流高压混联系统为例	112
6.5.1 测试系统与数据生成.....	112
6.5.2 数值测试结果分析.....	112
6.6 本章小结.....	113
第 7 章 总结和展望	115

7.1 研究工作总结.....	115
7.2 后续工作展望.....	116
参考文献.....	118

缩略语说明

ACGAN	辅助分类器生成对抗网络 (Auxiliary Classifier Generative Adversarial Network)
ADASYN	自适应合成采样 (Adaptive Synthetic Sampling)
BN	批归一化 (Batch Normalization)
BS	二分采样法 (Binary Sampling)
CAM	类别激活映射图 (Class Activation Mapping)
CCT	极限切除时刻 (Critical Clearing Time)
CNN	卷积神经网络 (Convolutional Neural Networks)
DAEs	微分代数方程组 (Differential Algebraic Equations)
DBN	深度置信网络 (Deep Belief Networks)
DCGAN	深度卷积生成对抗网络 (Deep Convolutional Generative Adversarial Network)
DEEAC	动态扩展等面积法 (Dynamic Extended Equal Area Criteria)
DL	深度学习 (Deep Learning)
DRSN	深度残差收缩网络 (Deep Residual Shrinkage Network)
DSA	动态安全评估 (Dynamic Security Assessment)
DT	决策树 (Decision Tree)
EEAC	扩展等面积法 (Extend Equal Area Criterion)
FAWGAN-GN	梯度归一化全注意力 WGAN (Full Attention Wasserstein Generative Adversarial Network with Gradient Normalization)
FFN	前馈神经网络层 (Feed-Forward Network)
FID	Fréchet Inception 距离 (Fréchet Inception Distance, FID)
GAN	生成对抗网络 (Generative Adversarial Network)
GAT	图注意力深度学习网络 (Graph Attention Network)
GNN	图神经网络 (Graph Neural Networks)
GRU	门控循环单元 (Gated Recurrent Units)
IN	实例归一化 (Instance Normalization)
LIME	局部可解释方法 (Local Interpretable Model-agnostic Explanations)

LLI	局部线性解释模型 (Local Linear Interpreter)
LN	层归一化 (Layer Normalization)
LSVM	线性支持向量机 (Linear Support Vector Machine)
MLP	多层感知机神经网络 (Multilayer Perceptron)
MPNN	消息传递图神经网络 (Message Passing Neural Network)
MSA	多头自注意力层 (Multi-head Self-attention)
NPCC	东北电力协调委员会 (Northeast Power Coordinated Council)
PCA	主成分分析 (Principal Component Analysis)
PEBS	势能界面法 (Potential Energy Boundary Surface)
PMU	相量测量单元 (Phasor Measurement Unit)
PST	Power System Toolbox
RBM	受限玻尔兹曼机 (Restricted Boltzmann Machine)
RUEP	相关不稳定平衡点 (Relevant Unstable Equilibrium Points)
SAE	堆栈自动编码器 (Stacked Autoencoder)
SAGAN	自注意力生成对抗网络 (Self-attention Generative Adversarial Network)
SCADA	数据采集与监视控制系统 (Supervisory Control And Data Acquisition)
SCP	切片 Cramér 保持 (Sliced Cramér Preservation)
SHAP	Shapley 加性解释方法 (Shapley Additive Explanations)
SMOTE	合成少数类过采样技术 (Synthetic Minority Oversampling Technique)
SVM	支持向量机 (Support Vector Machine)
TDS	时域仿真法 (Time Domain Simulation)
TSA	暂态稳定评估 (Transient Stability Assessment)
TSI	暂态稳定指数 (Transient Stability Index)
UEP	不稳定平衡点 (Unstable Equilibrium Point)
ViT	Vision-Transformer
WAMS	广域测量系统 (Wide Area Measurements Systems)
WGAN	Wasserstein 生成对抗网络 (Wasserstein Generative Adversarial Network)
LSTM	长短期记忆递归神经网络 (Long Short Term Memory)

第1章 绪论

1.1 选题背景

电力系统是国民经济和社会发展的战略性系统，是现代社会规模最大、覆盖最广、最复杂的人造系统之一，电力系统的安全稳定运行是保障经济、社会发展的重要基础^[1, 2]。随着电力电子设备的大规模应用和特高压交直流互联等新兴技术的高速发展，电力系统的复杂性增加且运行方式更加多样^[3]，这对电力系统的安全性和稳定性提出了更高的要求。

21 世纪以来，全球范围内频繁发生由于自然灾害、人为失误或恶意攻击导致的大停电事故^[4, 5]。例如，2018 年，巴西发生了因断路器过载保护动作引发的连锁反应，导致区域电网与主网解列，最终造成大范围停电，负荷损失高达 18GW，占巴西全国联网系统的 22.5%，影响了全国四分之一的用户。2022 年，台湾发生大规模停电事故，由于人为误操作叠加保护拒动，最大电力缺口达 1050 万千瓦，相当于全台用电需求的 1/3，总计停电户数约 549 万户。这些事故的经验和教训表明，电力系统因故障引发的暂态失稳是大范围停电事故的主导因素，对社会安全、经济生产及人民生活造成了严重影响。因此，如何确保电力系统的暂态稳定成为电力系统安全运行的核心问题之一。

传统电力系统暂态稳定研究通常采用基于稳定机理的建模和分析方法。通过对电网元件和动态特性进行建模，深入理解系统稳定机制，为优化电网运行和控制提供了有力支持。然而，新型电力系统中的运行方式更加多样、潜在故障点增多，系统动态特性的复杂性和时变性增强，这使电力系统的暂态稳定机理更加复杂，显著增加了暂稳评估物理模型的建立和求解难度。因此，传统基于稳定机理的暂稳分析方法难以满足对新形态复杂电力系统安全评估的需求。

近年来，以深度学习（Deep Learning, DL）^[6]为代表的人工智能方法逐渐成为暂态稳定评估研究的热点领域^[7]。深度学习的暂态稳定评估方法基于大规模的电气数据，利用神经网络强大的特征提取能力，以端对端的方式挖掘提取电气数据中蕴含的变量特征，构建当前运行点和暂稳预测之间的复杂映射关系，避免了物理建模和求解的困难，有助于复杂系统的暂态稳定评估分析。

另一方面，我国电网中量测和通信技术迅猛发展，数据采集与监视控制系统（Supervisory Control And Data Acquisition, SCADA）收集了大量历史量测数据，省级电网调度中心的全年 SCADA 量测数据量记录达到 TB 级^[8]。同时，基于相量测量单元（Phasor Measurement Unit, PMU）的广域测量系统

(Wide Area Measurements Systems, WAMS)能够以较高频率实时获取电力系统信息^[9]。这些技术为人工智能暂稳评估提供了离线训练的数据储备和在线评估的实时数据源。

上述技术的发展为人工智能暂态稳定评估提供了坚实的基础。然而，当前以深度学习为代表的驱动模型在暂态稳定评估应用中依然面临一些挑战。

① 智能算法对训练样本要求高，临界样本匮乏限制了模型对暂稳评估边界的刻画能力；② 模型性能受数据缺失影响大，基于完整离线样本训练的暂稳评估模型面向在线数据丢失时无法维持准确性；③ 深度学习模型自身的可解释性低导致算法可信性差，限制了模型在真实电力系统中的应用。

基于以上分析，本文的主要研究目标在于深入研究基于深度学习的电力系统暂态评估技术，从高价值数据集的构建、缺失数据的重建以及可解释评估模型的建立等多个角度，提升暂态稳定评估模型的评估可靠性和适用性，增强现代电力系统的暂态安全稳定运行能力。

1.2 电力系统暂态稳定评估及其经典方法综述

电力系统稳定性在国标 GB 38755-2019^[10]中被定义为“电力系统受到扰动后保持稳定运行的能力”，其包括功角稳定、频率稳定和电压稳定三大类及多个子类，如图 1-1 所示。本文关注重点为大扰动下的功角稳定。




图 1-1 电力系统稳定性分类
Fig. 1-1 Classification of power system stability

图 1-1 所描述的稳定性问题主要关注电力系统机电暂态分析，以关注单一稳定平衡点的李雅普诺夫稳定性为基础。根据《电力系统安全稳定导则》^[10]的定义，功角稳定表示同步互联电力系统中的同步发电机在受到扰动后维持同步运行的能力。根据扰动的大小，功角稳定可分为小扰动功角稳定和大扰动功角稳定。

小扰动功角稳定是指扰动足够小，可以通过基于线性化方程的特征根分析方法进行数学分析。另一方面，暂态稳定是指电力系统在受到大扰动后，各同

步发电机保持同步运行并过渡到新的或恢复到原来的稳态运行方式的能力。通常，这涉及到保持第一、第二摇摆不失步的功角稳定。因此，暂态稳定评估的首要任务是验证电力系统在遭受较大扰动后是否能够恢复到平衡状态。

根据不同的应用场景，暂态稳定评估分为两类：第一类是评估电力系统在预想故障下的暂态稳定性，即安全域下的动态安全评估（Dynamic Security Assessment, DSA）^[11]；第二类不考虑预想故障，评估电力系统是否当前或即将进入暂态失稳状态，即稳定域下的暂态稳定评估（Transient Stability Assessment, TSA）^[12]。

在安全域下的暂态稳定评估方法中，如果电力系统能够在预想故障下维持正常运行状态，那么该系统被认为是安全的；否则，系统被视为不安全或处于预警状态^[13]。这为电网调度运行人员提供了实施预防控制的可能性。一旦发现当前电网潮流存在暂态失稳的风险，可以通过对电源或电网拓扑结构进行优化调整^[14]，使调整后的潮流远离失稳边界，从而保障电网的安全运行。

在稳定域下的暂态稳定评估方法中，不以预想故障为先决条件，而是评估电力系统是否处于或即将进入暂态失稳状态，或者定量评估电力系统的暂态稳定裕度。其目的是为故障发生后的紧急控制提供预警信息。如果评估结果为“失稳”，则需要采取切机、切负荷等紧急控制措施，以确保电网的安全稳定运行^[15]。

长时间以来，国内外进行了大量关于电力系统暂态稳定评估的研究。目前，基于物理机理分析的暂态功角稳定性分析方法主要包括时域仿真法、直接法（能量函数法）、轨迹分析法。

1.2.1 时域仿真法

时域仿真法（Time Domain Simulation, TDS）的核心思想是利用数值积分算法求解受扰前后系统微分代数方程组的数值解，从而得到系统状态量和代数量随时间的变化曲线。最终，通过分析发电机转子之间的相对摇摆曲线来判断系统在受扰后的暂态稳定性。

仿真法的步骤通常涉及系统中各元件的数学模型的建立，并通过元件之间的连接关系形成整个系统的微分代数方程组（Differential Algebraic Equations, DAEs）。这一方程组的表达可以用如下式表示：

$$\begin{cases} \dot{x} = f(x, y) \\ 0 = g(x, y) \end{cases} \quad (1-1)$$

式中， x 代表系统状态变量的向量，例如发电机状态量（功角、转速、直轴暂态电势等）、励磁系统状态量、调速系统状态量、电力系统稳定器状态量和其

它状态量； y 代表系统代数变量，例如电力网络中的电压和相角； f 表示微分方程组，描述发电机、调速器、励磁调节器、电力系统稳定器、无功补偿、直流输电、负荷、继电保护等一次设备和二次装置动态特性的微分/差分方程； g 表示连接系统各动态元件的网络代数方程组。

目前，时域仿真法是电力系统安全稳定分析的成熟且可靠的方法。它被广泛应用于电网运行和规划的众多领域，如暂稳校核、方式计算、日前日内分析等^[16]。主流的时域仿真软件包括 PSASP^[17]、BPA^[18]、PSS/E^[19]、DSATools^[20]等，这些软件已经在学术界和工业界取得了广泛认可。时域仿真的优势主要体现在以下几个方面：直观性强，能够提供各种变量随时间的直观变化曲线；适应性强，适用于不同的元件模型、故障场景和系统规模；提供准确可信的结果，可作为验证其他暂态稳定评估方法准确性的标准。

为提高暂态稳定分析的效率，已有研究提出改进方法。文献[21]通过建立多机电力系统的发电机电磁功率分群后的等值参数表达，减少了计算所需的微分方程个数，确保了准确度的同时降低了计算的复杂性，提高了分析效率。文献[22]基于暂态稳定仿真中隐式梯形积分的局部截断误差理论，提出了变步长的非诚实牛顿时域仿真算法，并给出了相关的修正策略。通过保持迭代过程中的雅可比矩阵不变，这种方法加快了时域仿真的速度，提高了计算效率。文献[23]提出了基于相轨迹凹凸性的时域仿真快速终止算法。该方法通过分析系统暂态过程中相轨迹凹凸性的变化特征，实现了仿真的快速终止。这种策略在保持计算精度的同时，有效提高了计算效率。

然而，暂态稳定问题时间尺度通常为毫秒级至秒级，时域仿真方法运算耗时长，难以在线应用。此外，随着电力元件种类和数量的增加，时域仿真技术也面临更大的挑战。

1.2.2 直接法

直接法基于能量函数的建立，利用李雅普诺夫理论对电力系统稳定性进行分析研究。该方法通过比较故障清除时刻系统暂态能量 V_{cl} 与临界能量 V_{cr} 的关系，直接评估系统的暂态稳定性，无需对故障后的系统进行积分运算，能够实现对暂态稳定性的快速判断。相较于时域仿真法，该算法不仅省去了耗时的时域仿真，同时还能提供系统稳定裕度等指标。该算法首次提出于 1947 年^[24]，随后 Aylett^[25]、Gless^[26]和 Nagappan^[27]等人通过李雅普诺夫函数对电力系统的暂态稳定性进行了相关研究。在 80 年代，直接法得到了快速发展，Fouad^[28]提出了暂态能量的表达式，推动了直接法在多机电力系统中的应用。

在寻找暂态能量函数的临界能量 V_{cr} 方面，文献[29]采用了相关 UEP 法

(Relevant Unstable Equilibrium Points, RUEP), 该方法通过寻找最相关的电力系统不稳定平衡点 (Unstable Equilibrium Point, UEP), 改善了 UEP 法的保守性, 并且提高了计算速度。文献[30]提出了势能界面法 (Potential Energy Boundary Surface, PEBS), 用于计算故障期间发电机功角轨线位能边界曲面的出口点。该方法通过搜索的方式寻找最大势能, 并将此势能作为 V_{cr} 。文献[31, 32]进一步确定了势能边界面准确计算的条件, 并提出了稳定域的概念。

为提升直接法的计算速度, 薛禹胜等人提出了扩展等面积法 (Extend Equal Area Criterion, EEAC) [33-35]。该方法将多机系统等效为单机无穷大系统 (One-machine Infinite-bus System), 将系统中的多台发电机划分为同调的两群, 然后在等效系统上进行暂态能量分析, 包括加速面积和减速面积。相比于 RUEP 法和 PEBS 法, EEAC 在计算速度上更为迅速, 但由于其采用了单机无穷大等值, 可能导致一定程度的准确性损失。为弥补这一不足, 动态扩展等面积法 (Dynamic Extended Equal Area Criteria, DEEAC) [36]根据实际的多机运动轨迹, 动态修正 EEAC 在等值两机系统上的功率曲线参数或数值映象。这使得 DEEAC 能够自动识别关键机组, 并在精度上相较于 EEAC 有显著提升。

相较于时域仿真法, 直接法具有更快的计算速度, 并能够通过严格的数学推导给出系统层面的稳定裕度度量, 成为评估事故严重程度的工具。此外, 直接法得出的结论具有明确的物理含义, 有助于运行人员理解电力系统的特性和规律, 为实际运行提供理论基础。然而, 直接法也具有局限性, 包括模型适应性较差以及临界能量计算难度大等问题。

1.2.3 轨迹分析法

新型电力系统中实时量测系统的应用推进了轨迹分析法的发展, 轨迹分析法认为电力系统在暂态过程中的轨迹是实际物理过程的响应。通过选取合适的实测轨迹数据作为信号源, 并配合相应的算法进行分析, 可以有效评估系统的暂态稳定性。常见的轨迹类型包括发电机动能—功角曲线、功率—功角特性曲线、角速度—功角相轨迹等[37]。

文献[38]引入了功角曲线的历史信息 and 未来走势信息, 通过快速分群并结合电磁功率—角度轨迹穿越动态鞍点时的斜率和功角, 提出了一种综合判据, 用于判别轨迹遇到动态鞍点时的稳定性。这种方法充分考虑了功角曲线的演变趋势, 为系统稳定性提供了全面的评估。文献[39]通过扩展相平面轨迹拟合曲线的形状, 快速计算了发电机在故障后的暂态稳定指标。该方法通过发电机动能—功角曲线形状描述发电机的暂态稳定性, 为定量评估发电机承受故障的能力提供了有效手段。文献[40]分析了故障后的系统势能轨迹, 并发现系统稳定

时最小势能与故障清除时间呈线性关系，失稳时最大势能与故障清除时间呈线性关系，由此推导临界切除时间的计算式。文献[41]基于 WAMS 同步轨迹信息分析了暂态不平衡能量变化率与系统多摆稳定性的关系，并提出了多摆稳定性识别判据，能够从同步轨迹信息中有效地评估系统的稳定性。文献[42]在二阶非线性自治系统上证明了相对稳定平衡点为凹的相轨迹是失稳的相轨迹，从而利用相轨迹凹凸性识别多机系统的暂态稳定性。这一方法仅使用观测数据，不受运行时刻网络结构、系统参数和模型的影响，提高了实际应用的灵活性。文献[43]根据位能脊的定义，推导了基于单机广义暂态能量的改进位能脊公式，并提出了一种判断系统稳定性的方法，避免了能量函数的积分过程，为系统稳定性评估提供了更简洁的途径。文献[44]提出了一种基于相平面上转速差—功角差变化趋势辨识电网暂态功角稳定性的方法，揭示机械动能与电势能相互转化时系统维持同步运行的表现形式。

综上所述，轨迹分析法评估电力系统暂态稳定性不依赖于数据建模且无需迭代求解微分代数方程，仅需分析轨迹特征，具有快速、准确和易操作的优点。然而，这种方法也存在局限性。首先，轨迹分析法对暂态不稳定的识别高度依赖于发电机转子和转速的测量数据，由于建设成本的限制，PMU 并未在所有发电机母线上广泛应用，这可能导致数据不完整，从而影响分析精度。其次，采用单机无穷大系统的暂态不稳定判据，失稳判别时刻接近系统过不稳定平衡点的时刻，留给紧急控制的时间很短，可能影响对不稳定事件的应对效果。

1.3 基于人工智能的暂态稳定方法综述

人工智能作为一种数据驱动的技术，近年来在电力系统领域取得了显著的进展。当前，数据驱动已经成为科学研究的主要方法论之一，推动了科学研究逐渐由传统的“理论科学”、“实验科学”和“计算科学”向“数据密集型科学（数据驱动）”演变^[45]。数据驱动算法通过学习训练数据并优化模型，从数据中抽象出一般性规律。

数据驱动的人工智能技术从模式识别的角度研究电力系统的安全稳定评估问题，将电力系统暂态稳定分析问题转化为高维空间内的分类问题，其核心思想是建立系统状态量输入与暂态稳定性输出之间的映射关系，以替代传统的仿真分析或基于理论模型的分析。通过训练人工智能模型，避免求解复杂的微分代数方程组，仅需进行一次前向代数计算即可得到结果，满足了在线评估的时效性要求。随着新型电力系统的高维、时变、非线性特性增强，基于物理机理的暂稳评估方法难度随之增大。而数据驱动技术能够自动学习和提取电力系统中的复杂特征，在处理高维电气数据时展现出卓越的性能。

深度学习是数据驱动技术的重要范例，推动了第三次人工智能的迅猛发展^[6]。深度学习通过多层次的神经元组织和大规模的训练数据，不仅具备强大的表达能力和学习能力，还能够直接从原始数据中学习高级抽象特征。在计算机视觉、语音识别、图像分类、自然语言处理等领域，深度学习取得了显著的成就^[46]。而在电力系统的暂态稳定评估中，深度学习可以利用大规模的电气数据捕捉电力系统中各种因素的复杂关联^[47]，包括发电机的动态行为、负荷变化和网络拓扑变化等^[48]。因此，数据驱动的人工智能技术在电力系统的暂态稳定分析中具备巨大的潜力。

基于数据驱动的暂态稳定评估通常包括离线训练和在线评估两个阶段，如图 1-2 所示。在离线训练阶段，利用时域仿真数据和历史数据构建原始数据集，然后对原始数据进行特征处理。需要注意的是，不同的算法结构设计思路对应着不同的数据库建立需求，因此需要使用不同的特征处理方法处理原始数据集，例如将原始数据处理为一维数据以满足决策树（Decision Tree，DT）的需求。离线阶段的最后一步是将大规模的数据送入算法进行离线训练，训练的目的是使数据驱动模型充分学习样本输入与输出之间的映射关系。训练完成的数据驱动模型用于在线评估，根据电力系统的实时运行数据，快速得出电力系统的暂态稳定评估结果。




图 1-2 基于数据驱动的暂态稳定评估模型构建框架

Fig. 1-2 Framework for constructing a data-driven transient stability assessment model

下面将从图 1-2 中所示的三个主要环节，即数据库建立、特征工程和算法设计三个方面介绍人工智能技术在暂稳评估流程中的应用。

1.3.1 人工智能暂稳评估方法的数据库建立

在数据驱动的暂稳评估方法中，构建样本集是至关重要的一步。通过建立覆盖电力系统状态空间的大规模样本集合，确保数据驱动模型能够学习电力系统动态特性，从而准确刻画暂态稳定边界。

现有研究通常通过时域仿真方法生成暂稳评估模型的数据库集合。建立数据集时，主要考虑负荷变动、发电机出力以及电网拓扑的变化等因素^[49, 50]。为了确保生成的样本更符合实际电网的运行状态，文献^[51]基于系统监测信息

和实际电网运行状态，构建发电和负荷的概率模型，而文献[52]进一步考虑了故障概率分布，建立更符合实际系统运行状态的数据集合。

随着广域监测系统在电力系统中的广泛应用，直接采用大规模的电气历史数据训练模型成为可能^[53]，从而节省时域仿真的耗时。然而，电力系统历史记录难以直接作为数据驱动模型的训练集合，其中失稳样本的匮乏是最明显的数据问题之一。由于实际电网中的历史数据主要集中于正常运行方式，故障情况很少见，这给数据驱动模型的训练带来了很大难度。因此，需要采用数据生成技术生成面向具体任务需求的电气数据。

下文以失稳样本生成为例，阐述现有的电气样本生成方法。传统方法通过重采样少量类别的样本，如合成少数类过采样技术（Synthetic Minority Oversampling Technique, SMOTE）^[54]和自适应合成采样（Adaptive Synthetic Sampling, ADASYN）^[55]，用于失稳样本的生成。文献[54]提出了一种结合了 k-means 聚类 and SMOTE 的重采样方法，以增加不稳定样本在数据集集中的比例。然而，这些插值算法在处理非线性系统时能力有限，难以捕捉电力系统的潜在特性，最终可能导致暂态评估算法的过拟合^[56]。

为解决上述问题，基于深度学习的数据生成算法得到广泛应用，其中包括生成对抗网络（Generative Adversarial Network, GAN）。文献[57]基于对抗博弈思想，学习原始数据集中复杂的电力系统时空分布，并通过引入注意力机制和谱归一化来稳定训练过程。文献[58]使用辅助分类器 GAN（Auxiliary Classifier Generative Adversarial Network, ACGAN）学习小样本集的边界分布，并通过监督学习属性生成多样化的样本。文献[59]从电力系统的故障前数据中学习到的复杂的分布，显著提高了暂态稳定评估模型对失稳样本的识别率。文献[60]利用深度卷积 GAN（Deep Convolutional Generative Adversarial Network, DCGAN）生成额外的失稳样本，并利用卷积神经网络（Convolutional Neural Networks, CNN）捕捉扰动特征和稳定性类别之间的非线性关系。此外，文献[61]通过循环生成对抗网络解决了历史数据库中样本量少和类别不平衡的问题。另外，文献[62]提出了一种基于双生成器生成对抗网络的暂态稳定评估方法，该方法能够批量生成符合真实数据分布的新样本，并引入基于长短期记忆融合机制的自编码器，不仅能有效抵抗暂态数据中的噪声干扰，还能够应对局部数据缺失问题，确保数据的完整性和准确性。

1.3.2 人工智能暂稳评估方法的特征工程

广域量测系统为数据驱动的电力系统暂稳评估方法提供了数据基础，然而，量测数据通常包含系统多个节点和多种特征的信息。如果直接将这些信息全部

输入智能模型进行训练，将耗费大量计算资源，冗杂的数据也可能影响模型的训练效果。因此，需要对原始样本进行特征工程处理，即筛选或提取出对暂稳评估最具价值的特征。常见的特征工程包括基于专家经验和固定规则的特征处理，以及基于机器学习的特征处理方法。

基于专家经验的处理方法是一种常见的特征降维方法，在暂态特征选取方面已经得到广泛应用。文献[49, 63–65]中的暂态特征通常包括故障前、故障发生时以及故障切除后系统内各发电机的关键状态量，如发电机功角、角速度、角加速度、动能、电磁功率等，以及一些与系统规模无关的系统工况统计量。在文献[64]中，通过使用故障清除后的发电机转子角度定义 27 个轨迹聚类特征，作为深度置信网络（Deep Belief Networks, DBN）的输入。这种特征选择方法的优势在于其特征维度不会受电网规模影响。而文献[65]则从各发电机频率上提取最大频率偏移构建向量，计算不同时刻频率的欧氏范数并作为多层感知机神经网络（Multilayer Perceptron, MLP）的输入特征。此外，文献[49]采用系统内所有发电机的动态轨迹，包括相对转子角度、转速、加速度、动能以及相对电磁功率，作为暂稳评估算法的输入参数。文献[66]采用系统特征而非单机特征作为 DBN 的输入，因此特征维数不随系统规模的变化而变化，满足大系统暂态稳定评估的需求。尽管基于专家经验的特征选择方法在实际应用中取得了一定的成功，但也存在主观性、局限性和泛化性低的缺点。

基于固定规则的降维方法也是常用的预处理方式，例如文献[67]采用主成分分析（Principal Component Analysis, PCA）提取关键特征，从而降低算法复杂度。文献[68]通过计算互信息（Mutual Information）对原始电气量进行初步分析，筛选出与系统稳定性关联度较高的特征属性，再利用线性判别分析方法对选定属性进行最佳投影，获得各决策属性的组合特征。此外，文献[69]通过 Tabu 搜索技术从维数较大的初始特征集中选择有效特征，从而显著地降低了输入空间的维数；文献[70]将响应数据构建的原始特征集映射至高维特征空间，进而降低暂稳模型的时间和空间复杂度。而文献[71]提出了一种基于 Relief 的方法来计算时序特征的重要性，以建立最优 PMU 聚类搜索模型，获得基于特征重要性的时序特征子集，以降低由于数据丢失带来的暂稳预测性能下降风险。这些降维方法的主要限制在于对数据有一定的前提假设。例如，PCA 假设数据具有线性可分性，并可通过线性变换找到最佳的主成分表示；而 Relief 则基于数据存在邻近性的假设，通过计算特征之间的邻近关系选择最相关的特征。然而，这些假设并不总是适用，特别是在电力系统的非线性动态特性下，可能会影响降维效果。另外，固定规则的降维方法往往仅关注数据特征，而忽视了目标变量，这可能导致特征提取结果与任务需求不符。

为克服上述方法的不足，一些研究采用浅层智能算法进行特征筛选和提取，

以增强对非线性系统的提取能力。文献[72]通过对 PMU 量测数据进行时域和频域处理,例如计算角度的峰值谱密度、频率及它们的点乘积,根据特征与决策树分类边界的相关性进行决策树模型的特征选择。在文献[73]中,首先使用线性支持向量机(Linear Support Vector Machine, LSVM)对发电机转子角轨迹簇整体特征的时间序列进行降维映射,然后将降维后的特征作为暂稳分类模型的输入。文献[74]提出了一种基于随机森林和递归特征消除的特征选择算法,用于提取暂态稳定评估的关键特征子集。此外,文献[75]提出了一种基于 XGBoost-EE 的电力系统暂态稳定评估方法,采用 XGBoost 算法的路径规则生成类别特征,实现对原始特征的降维,并通过实体嵌入网络进行暂稳分类。

深度学习的快速发展降低了模型对特征工程的需求。深度学习算法将“表示”和“学习”融合在一起,能够直接从系统量测信息中提取特征。文献[76]提出一种基于深度学习的异构数据特征融合方法,解决电力系统输入数据不全面、忽略异构数据以及无法有效融合多种特征信息的问题。该方法首先对电力系统的拓扑图域数据和时序多变量数据进行特征提取,然后通过融合所有提取到的特征,利用基于同方差不确定性的学习方法更全面地描述电力系统。文献[77]使用深度自编码器将原始状态变量(如潮流)转换为更低维度,建立了暂态判稳特征提取的框架结构。综上所述,基于深度学习的暂稳评估方法不仅减少了对前期特征工程的依赖,还能够捕捉系统量测中的隐藏特征,进一步提升模型性能。

1.3.3 人工智能暂稳评估方法的算法设计

数据驱动的暂稳评估模型设计紧随计算机领域模型发展的步伐。在早期,暂稳评估模型主要为浅层神经网络,包括人工神经网络^[78]、决策树^[68, 79]和支持向量机^[50, 80, 81]等。文献[81]提出了一种基于 PMU 量测信息的两阶段暂态稳定分析方法,第一阶段通过识别暂态稳定性进行预测,第二阶段识别发电机状态以判断失稳机组。文献[50]采用母线电压幅值作为支持向量机(Support Vector Machine, SVM)的输入,该方法成功应用于对称和非对称故障,并在随机测量误差和网络拓扑变化时表现出较高的鲁棒性。此外,文献[80]验证了 SVM 在巴西电网 2684 节点系统上的适用性。

随着深度学习技术的不断进步,暂稳评估模型已从浅层神经网络逐步发展至深层神经网络。深度神经网络具备更强的学习和泛化能力,在解决电力系统暂态稳定分析问题上取得了显著进展。例如,文献[82]采用深度置信网络通过无监督特征提取过程学习数据分布,对暂稳问题呈现出良好的鲁棒性。考虑到电力系统的暂态失稳过程是一个动态过程,文献[83]和文献[71]直接将故障后

系统状态的时间序列输入到长短期记忆递归神经网络 (Long Short Term Memory, LSTM) 中进行暂态判稳, 并取得了显著效果。文献[15]提出了基于 CNN 的连续在线监测系统, 通过滑动窗口持续监测电压曲线并生成稳定性预测结果。文献[84]引入代价敏感损失函数到堆栈自动编码器 (Stacked Autoencoder, SAE) 中, 以提高 SAE 对失稳样本的评估能力, 而文献[85]在 SAE 框架中的最后隐藏层加入卷积结构, 以进一步提高评估性能。此外, 在文献[86]中, 通过采用基于连续学习的切片 Cramér 保持 (Sliced Cramér Preservation, SCP) 算法, 实现对模型的更新操作。该方法使用深度残差收缩网络 (Deep Residual Shrinkage Network, DRSN) 作为分类器, 构建了基于 SCP-DRSN 的 TSA 模型。通过引入 SCP 算法, 只需使用新的场景数据就可以扩展和更新模型。这种连续学习方法使得模型能够不断适应新数据并保持其性能, 为电力系统暂态稳定评估模型的持续优化提供了有效的手段。

同时, 电力系统在运行中经常面临拓扑结构的变化, 这需要训练完成的暂稳评估模型能够适用于新的运行拓扑场景。图神经网络 (Graph Neural Networks, GNN) 等网络结构在处理这类问题上表现出独特的优势。在文献[87]中, 考虑了电力网络中母线特性和拓扑连接关系对电力系统暂态稳定性的影响, 构建了基于图神经网络算法的暂态稳定评估模型, 具有良好的拓扑泛化能力。另外, 文献[88]提出了一种基于消息传递图神经网络 (Message Passing Neural Network, MPNN) 的稳态数据暂态稳定评估方法, 通过图数据处理和拓扑连接关系建模, 训练出能够描述电力系统拓扑变化的暂态稳定性评估模型。文献[89]引入图注意力深度学习网络 (Graph Attention Network, GAT) 建立基于动态特征的暂态稳定评估模型, 在考虑节点之间拓扑关系的基础上, 进一步引入了考虑相邻节点特征相关性的注意力机制, 其注意力系数在节点特征聚合过程中自适应变化。然而, 这类算法依赖于电网拓扑结构信息, 增加了数据驱动暂稳评估模型的建立难度。

此外, 集成学习思想在暂态稳定性分析领域得到广泛应用, 旨在通过构建多个分类器提升整体评估模型性能。文献[13, 90]通过采用集成学习方法实现了故障前的动态安全评估, 文献[90]通过对关键样本赋予更高权重进一步改进了性能。在文献[91]中, 首先使用网格法对支持向量机进行参数寻优, 然后通过选取准确率最高的若干组支持向量机构建了集成模型, 实现电力系统暂态稳定评估。文献[92]构建了多个结构相同但参数不同的 CNN 模型, 综合子模型结果以得出暂稳评估结论。文献[93]提出了基于多径向基函数极限学习机集成模型的暂稳评估方法, 通过采用多个子模型构建集成模型, 获得更可靠和准确的稳定性评估结果。文献[94]则提出了基于集成学习的时间自适应电力系统暂态稳定评估方法, 通过多个 LSTM 分类器输出样本在不同评估时刻的稳定性预

测结果，更全面地评估电力系统的暂态稳定性。然而，集成学习需要较高的计算资源和时间成本，并可能导致模型的复杂性增加。

1.4 人工智能方法在暂态稳定评估中的挑战

根据上述分析，面向基于数据驱动的电力系统暂态稳定评估问题，人工智能方法的诸多优势得到了充分发挥，包括对电力系统潜在暂态特征的提取能力、对电气信息和暂稳预测结果的关联拟合能力，以及在线应用中的时效性，使得人工智能方法成为评估电力系统暂态稳定性的有效手段。

通过人工智能方法，现有研究在电力系统暂态稳定评估方面取得了显著成果。然而，基于人工智能的暂稳分析方法仍然存在面临一些挑战。首先，临界样本匮乏限制了数据驱动模型的建模效果和训练效率；其次，模型面向在线数据丢失时无法维持准确性；最后，模型可解释性低导致算法可信性差。本节将针对这三点挑战逐一讨论。

1.4.1 离线样本集合中临界样本匮乏

在数据驱动的暂稳评估模型训练过程中，评估模型的建模效果和训练效率受训练样本质量影响。具体来说，为了提高模型对安全边界的识别能力，模型训练需要大量的边界样本来学习安全边界特征^[95]。因此，如何构建能够充分刻画暂态稳定边界的训练样本集合，提升模型对电力系统暂态稳定知识的学习和提取能力，从而提高模型训练效率和性能，是建立数据驱动暂稳评估模型的一项重要挑战。

现有研究已经提出了多种方法构建模型分类边界的数据集。例如，文献[96]采用二分采样法（Binary Sampling, BS）的迭代方式，增加稳定边界附近的样本密度。文献[97]开发了一种基于决策树的高效采样策略，通过重要性采样算法生成可用于高效训练电力系统动态安全模型的数据。其第一阶段在多维操作参数状态空间中寻找高信息内容区域，第二阶段使用重要性采样偏向该区域，从而显著提高数据库信息内容，同时降低计算需求。文献[98]运用凸优化和复杂网络理论排除不可行区域，从而缩小搜索空间，并通过高度可并行化的算法探索剩余的空间，显著缩短了仿真时间。

然而，尽管上述算法已经构建了更高价值的数据集，提升了模型训练效率，但这些方法中生成的关键样本区域取决于所采用的决策树模型（如文献[97, 99]），导致由此构建的关键样本区域可能不适用于其他数据驱动模型。因此，有必要探索更通用的方法来生成暂稳评估任务的分类边界样本，使其能够有效地应用于不同的数据驱动模型。

1.4.2 现场数据部分缺失导致模型性能下降

当前,大多数基于数据驱动暂定评估模型的训练和建立依赖于完整的离线数据信息。这些模型假设离线和在线阶段的数据收集单元都能提供完整的测量数据。然而,实际情况是,无线传感网络的结构特点可能导致传感器故障、传感器噪声、PMU 故障、随机数据丢失和通信故障等数据问题,导致完整测量数据集合不可得,最终影响模型评估准确性^[100, 101]。在中国电网的日常运行中,异常/缺失数据约占 PMU 测量数据的 10%-30%^[100],这显著降低了数据驱动暂稳评估模型的在线应用可靠性^[71]。因此,降低不完整在线信息的影响对暂稳评估任务至关重要。

为了降低不完整在线信息对数据驱动暂稳评估方法的影响,集成算法是一种常见的解决方案。文献[102, 103]提出了采用不同 PMU 集合的集成模型,以确保在数据缺失的情况下保持模型性能。文献[71]进一步发展了考虑特征重要性的 PMU 聚类方法。然而,尽管集成算法在数据缺失时比单一结构模型鲁棒性更强,但也增加了计算负担,且有限的 PMU 聚类方案可能无法解决广泛的缺失 PMU 数据问题。同时,针对电力系统中的各种任务,现有研究已经提出了许多单一结构的数据驱动算法^[48],这些算法已经被证明具有较高性能。为了将这些算法应用于实际电网,需要建立缺失数据重建方法作为现有暂稳评估算法的前置模块,以避免集成模型的计算负担并保持现有算法的高性能。

在不采用集成算法思路解决在线信息缺失的方案中,文献[104, 105]采用基于时空矩阵低秩特性的高级矩阵优化技术,以恢复缺失的 PMU 数据。此外,在文献[106]中,通过交替方向乘法算法解决了 PMU 矩阵的补全问题。然而,这些方法在实际应用中受到一定限制,因为现实应用可能无法满足最低测量要求^[104]。

随着人工智能技术的发展,现有研究提出基于深度学习的数据补全方法。深度学习方法的基本思想是利用已知的数据来训练模型,使其学习数据真实的潜在分布,从而对缺失的数据进行补全。在电力系统中,动态信息通常具有时间关联性,因此基于循环神经网络的方法也被广泛应用于电力系统时空数据的修复。其中,门控循环单元(Gated Recurrent Units, GRU)^[107]和 LSTM^[108]在电网缺失数据预测方面表现出较高的性能。然而,在修复数据时,这些方法依赖于当前时刻的前序信息,而这些前置序列的数据可能在实际场景中无法获取。

为克服上述方法的缺点,GAN 网络作为一种新型的生成式网络,在重建缺失数据方面展现出显著的性能优势。例如,文献[101, 109]通过减少生成数据与真实数据之间的分布误差来进行数据重建。然而,与图像处理领域相比,

电网数据具有更强的物理规律约束。现有 GAN 网络在重建缺失电气数据时，普遍对电气数据的内部相关性挖掘不足。例如，文献[101, 109]中采用的 GAN 网络将生成数据作为整体去评估其真实性，但未充分挖掘特征图内部数据之间的时空相关性。因此，需要建立更具细粒度的算法，充分挖掘电网量测信息之间的时空依赖，以实现更适用于电力系统领域的数据重建方法。

1.4.3 深度学习可解释性不足

与暂稳评估的经典方法相比，传统深度学习的模型可解释性普遍不足。尤其是采用基于深度学习技术的评估模型，其“黑箱”性质导致模型只能获取暂稳评估结果，却难以追溯其过程及其原因。由于暂态稳定评估任务对高可靠性的需求以及误判可能带来的灾难性后果，电网调度部门对智能算法的决策存在一定的顾虑。

目前，已有一些研究对深层算法的可解释性展开工作，深层算法的可解释性主要有两种来源：

第一种方法是模型无关的可解释性方法，不依赖于具体的深层模型结构。例如，文献[110]采用局部可解释方法（Local Interpretable Model-agnostic Explanations, LIME）对 XGBoost 暂态稳定算法进行分析，以识别关键特征。另外，文献[82]提出局部线性解释模型（Local Linear Interpreter, LLI），用于探索电网特征与暂态稳定输出结果之间的关系。文献[111]提出加权线性回归和正则化构造局部代理模型的稳定评估机器学习模型通用解释方法，以得出状态变量与稳定水平之间的灵敏度和贡献度。此外，文献[112]提出了基于 Shapley 加性解释方法（Shapley Additive Explanations, SHAP）的归因分析框架，通过计算 Shapley 值来量化输入特征对模型输出结果的影响，并进一步得到特征重要性排序。

另一种可解释方法是对模型本身的内部参数进行分析。例如，文献[113]利用反卷积技术可视化了中间特征层的功能和分类器的运作方式。类似的，文献[114, 115]采用输入层的梯度作为输入特征的重要性指标，从输入特征的维度上获得解释区域。另一方面，文献[116]基于类别激活映射图（Class Activation Mapping, CAM）构建了通用的局部深层表示方法，从而揭示了卷积神经网络对图像的隐式关注基于激活映射。文献[117]在 CAM 的基础上，通过 Grad-CAM++ 方法，使用最后一个卷积层特征图对特定类别分数的正偏导数加权组合作为权重，生成类别标签的可视化解释。这些方法通过分析模型内部的参数和激活映射来提供模型的可解释性，使用户能够更好地理解模型的决策过程。

目前,关于电力系统中可解释性的研究仍处于较初级的阶段。为了更好地适应电力系统的特点,有必要探索更适用于该领域的可解释性方法。例如,尽管CAM类算法能够提供粗略的关键特征区域,但难以精准定位关键特征。因此,在暂稳评估任务中,需要建立更精确的电气特征可解释方法。此外,与图像识别领域不同,电力系统数据之间具有很强的时空相关性,因此需要建立能够更全面地提取时空变化的可解释方法,并能为电力运营商提供更有针对性的评估结果解释。

1.5 本文研究工作

1.5.1 研究框架

本文基于深度学习的电力系统暂态稳定评估问题展开研究,旨在提高稳定评估模型的可靠性和适用性。鉴于现有在线暂态稳定分析工作所面临的挑战(详见1.4节),本文主要涉及样本集合构建、数据重建和可解释性暂稳评估算法构建等多项研究,最终建立基于深度学习的暂态稳定评估架构。总体框架如图1-3所示。

本文最终的目标为:

1) 建立适用于电力系统暂态稳定评估的临界离线训练样本生成模型,分别构建安全域下的边界样本和稳定域下的失稳边界样本,旨在提高暂稳评估模型的准确性和训练效率;

2) 重建量测数据中的缺失数据,保持数据驱动暂态稳定评估模型在实际量测信息下的鲁棒性,提高模型的实际应用可行性。

3) 提出具有可解释性的暂稳评估模型,使决策者更容易理解和信任模型的暂稳评估结果。进一步,提出基于当前电网运行点的暂稳评估模型,使其不依赖于准确的故障清除时刻,且模型不需要由继保动作信号触发。

通过实现上述目标,本文旨在提升暂态稳定评估问题的可靠性和应用可行性,从而更好地将基于数据驱动的智能方法应用于电力系统的暂态稳定评估领域,提升我国电力系统运行的安全性和稳定性。

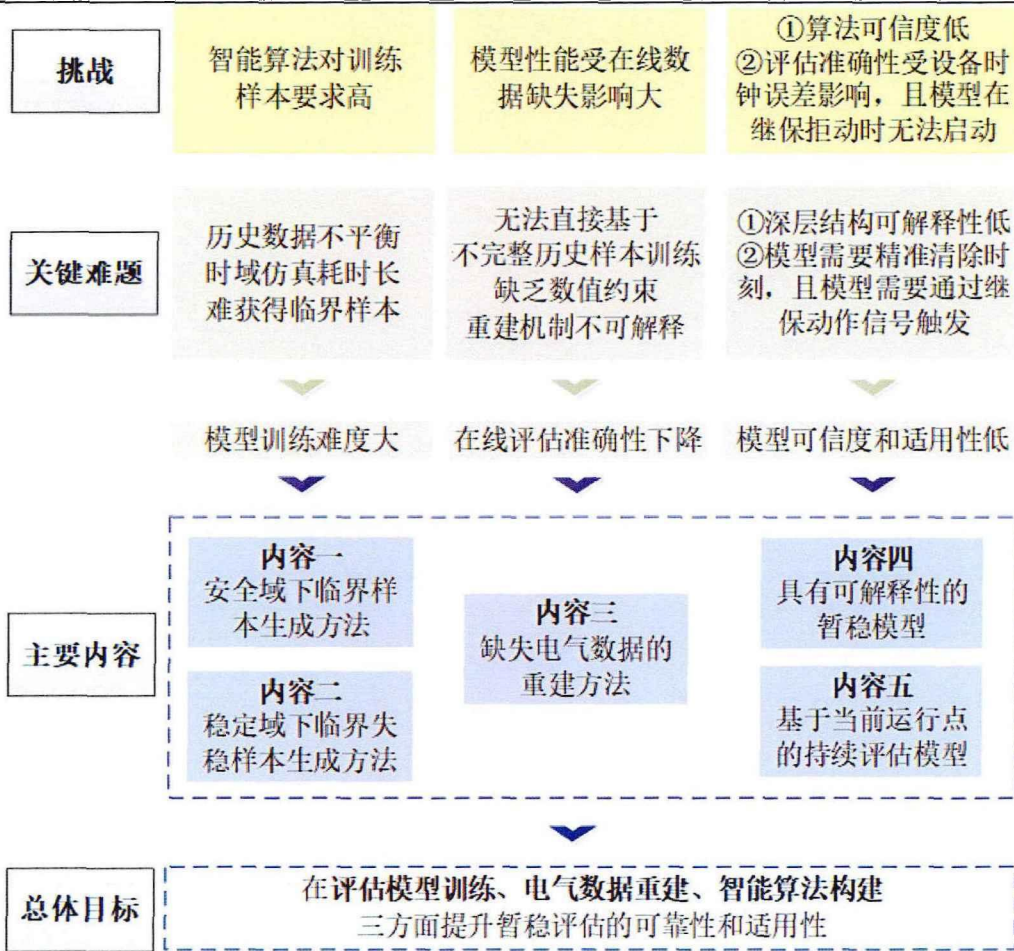


图 1-3 总体研究框架

Fig. 1-3 Overall research framework

1.5.2 拟解决的问题和研究思路

针对电力系统的暂态稳定评估，本文重点解决以下三个问题：

1. 包含大量临界样本的训练集合构建问题

根据前文的讨论，暂稳评估模型的离线样本构造存在以下问题：

1) 在故障前安全域下的暂稳评估任务中，样本集合中分类边界样本的比例较低，导致模型训练效率低，同时对边界样本的识别准确率低；

2) 在故障后稳定域下的暂稳评估任务中，由于历史数据集中失稳场景罕见，导致模型难以充分学习失稳特征。同时，训练集中临界失稳样本匮乏，导致模型对于临界失稳样本的识别准确率低。

为了解决上述问题，本文构建了具有以下特性的生成样本集合的方法：

1) 构建考虑样本临界程度的数据生成算法，大量生成分类边界样本，提升暂稳评估模型对暂态稳定知识的学习和提取能力，从而提升暂稳评估模型的

准确性和鲁棒性。

2) 建立能够大量生成临界失稳场景的样本生成模型, 平衡不同标签的样本比例, 提高模型对失稳样本, 尤其是临界失稳样本的识别能力。

本文面向不同的应用场合, 分别建立了能够生成安全域的分类边界样本和稳定域下的临界失稳样本的样本生成算法。本项研究可以为数据驱动暂稳模型提供数据基础, 有效提升现有数据驱动暂态稳定模型的训练效率和性能, 提高模型实用性。

2. 缺失数据重建问题

根据前文的讨论, 缺失数据重建存在以下问题:

1) 电网历史记录中存在数据缺失情况, 这种不完整的电网数据集不适用于训练现有的数据重建方法, 并增加了模型提取电网内部时空依赖的难度;

2) 深度学习模型关注学习数据的分布特性, 但缺乏对数值准确性的约束, 不利于准确恢复数据;

3) 数据重建过程呈现出“黑箱”的状态, 导致人们对电气数据的重建结果难以相信。

为了解决上述问题, 本文构建了具有以下特性的缺失信息重建算法:

1) 建立可直接基于不完整电网历史数据训练的高细粒度数据重建算法, 以像素级别提取电网时空特征, 从而提高模型的训练稳定性和重建准确性;

2) 建立引入数值约束的算法结构, 在损失函数中引入重建数值损失, 从而提高模型对数据的重建准确性;

3) 构建具有可解释性的数据补齐算法, 通过解释深层网络内部参数来帮助人们理解数据重建的过程, 从而提高算法在应用中的可信度。

这项工作可以嵌入到暂态稳定的评估流程中, 有助于为基于完整数据集训练的现有暂态稳定模型提供有效补充, 从而支持现有的数据驱动暂态稳定评估模型在实际场景中的应用。

3. 暂稳评估模型的可解释性和适用性问题

暂稳评估模型的建立是暂稳评估流程的核心部分, 目前在数据驱动模型的构建上存在以下问题:

1) 当前的深度学习模型解释性不足, 需要建立能够准确识别并关注暂稳关键特征的可解释方法, 模型内部参数通过提取并解释电力系统暂稳过程的时空信息, 提升算法在实际应用中的可信程度;

2) 暂稳评估模型通常在故障清除时刻由继保动作信号激活。然而, TSA模型的准确性受保护装置和 PMU 之间时钟误差影响, 且在继保拒动时无法启动。

为了解决上述问题, 本文设计了具有以下特性的暂态稳定评估模型:

1) 建立具有可解释性的暂态稳定评估算法, 模型内部注意力在训练过程中自适应向关键特征聚焦, 无需引入额外的可解释性结构。算法内部参数分布符合实际系统的物理关系, 提高算法的可信度;

2) 建立覆盖故障前到故障清除后的持续暂稳监测系统, 使算法仅基于当前操作点预测暂稳态状态, 不需要获知准确的故障清除时刻, 且不由继保动作信号触发。

这项工作提高了数据驱动暂稳评估算法的可信度和适用性, 使人们能够更清晰地理解模型的决策依据, 并提升了模型在实际中的应用潜力。

1.5.3 主要研究内容与章节安排

本文各章节间的整体关系如图 1-4 所示, 面向数据驱动暂稳评估模型训练和应用中的三个关键环节展开。本章每章内容构成了整体的电力系统暂态稳定评估系统, 包括离线训练和在线应用阶段, 如图 1-5 所示。

第 1 章介绍了研究背景和意义, 并对暂态稳定方向的国内外相关研究进行了综述, 重点讨论了人工智能在暂态稳定评估中的应用与挑战。在此基础上, 总结了已有研究的发展方向和不足之处。

第 2 章提出了安全域下的临界样本生成方法, 以解决评估模型对安全边界刻画能力不足及模型训练效率低的问题。该方法将卷积机制的监督结构整合到生成对抗结构中, 通过缩小生成样本的极限切除时刻与系统设定的故障切除时间之间的距离, 引导数据生成模型的优化方向, 确保生成的临界样本能够紧贴安全边界。本章提出的算法能够大量生成安全边界样本, 基于此建立的离线样本集合作为动态安全评估模型的训练样本, 能够有效降低模型所需的训练样本数量, 提升模型对失稳样本的识别能力。

第 3 章提出了在稳定域下生成失稳样本集合的方法, 其中包含大量的临界失稳样本, 以解决模型对临界失稳样本识别能力不足及模型训练效率低的问题。所提方法将映射故障清除时刻的电气量与失稳时间之间关系的回归模型融入到生成 GAN 结构中, 并通过改进生成器损失函数, 改变了原始失稳数据集失稳时刻的长尾分布。本章提出的算法能够生成大量真实性较高的临界失稳样本, 基于此建立的离线样本集合作为暂稳模型的训练样本, 可提升模型的训练效率以及对失稳样本的识别准确性。




图 1-4 各章节间的关系

Fig. 1-4 Relation between chapters




图 1-5 章节内容在暂态稳定评估流程中的应用

Fig. 1-5 The application of chapter contents in TSA process

第4章提出了基于生成对抗网络的缺失数据重建模型，以解决量测数据缺失导致TSA模型性能下降的问题。通过构建掩码矩阵结构，并改进生成对抗网络结构，实现了更具细粒度的算法，充分提取电网量测之间的时空依赖性。

同时，本文的损失函数考虑了生成数据和真实数据在分布和数值两方面的差异，提升模型的重建准确性。此外，所提方法具有一定的可解释性，模型内部参数的可视化展示了模型能够自适应地关注有效数据且避开缺失信息区域，进一步增强了在实际应用中的可信度。

第 5 章提出了一种可解释的暂稳评估模型，以解决现有暂态评估模型可解释性低导致模型难以被信任的问题。该模型基于自注意力编码器机制构建，通过展现深层网络内部工作过程，证明模型在训练迭代中能够自适应关注并聚焦于重要特征，所提算法呈现的内部参数分布符合实际系统的物理关系，提高了算法决策的可信度，并为未来的数据收集提供了方向。

第 6 章提出了一种持续暂稳监测方法，旨在实现暂态稳定性持续评估和失稳发电机组的预测。以解决现有暂稳评估模型需要由继保动作信号触发且受电气设备间时钟误差影响的问题。该系统根据当前操作点提供暂稳状态，无需依赖故障发生或清除信号，不受电气设备间时钟误差的影响，同时适用于继电器失效场景。同时，为了得到不同决策保守度下的失稳判定阈值，提出了一种自适应调整的失稳阈值设定算法，以进一步增加算法的适用性。

第 7 章结论与展望。对全文的研究工作和成果进行总结，并对未来的可行研究方向提出展望。

第2章 面向动态安全评估任务的边界样本生成方法

2.1 引言

在基于数据驱动的人工智能技术中，离线训练样本对模型的建立至关重要。在动态安全评估任务（Dynamic Security Assessment, DSA）中，为了提高模型对安全边界的刻画能力，模型训练需要大量的边界样本来学习安全边界特征^[95]，因此，分类边界样本对 DSA 模型的性能提升具有重要作用，现有方法中，离线数据集主要基于时域仿真方法构建^[11]。这种样本构建方法具有两个缺点，首先，时域仿真耗时较长；其次，时域仿真难以自适应搜索安全边界以高效获得边界样本，只能通过抽样或均衡采样得到少量接近安全边界的样本。

因此，本章提出一种安全边界样本生成方法，以大量生成 DSA 任务中的分类临界样本。本文修改了现有生成模型的算法结构及其优化目标。具体来说，本章建立了生成样本与极限切除时刻（Critical Clearing time, CCT）之间的有监督回归模型，并提出考虑样本与分类边界距离的损失函数。通过将监督结构融入生成对抗结构，使模型在优化训练过程中评估生成样本的 CCT 与电力系统故障切除时刻之间的距离，以此引导模型的优化方向，确保生成的临界样本紧密贴近安全边界。仿真结果证明，所提算法能够有效地生成大规模的安全边界样本，减少训练 DSA 模型所需的样本数量，并保持高准确性。

本章的主要贡献包括：

1) 提出了一种基于生成对抗机制的样本生成算法，生成大量与原始数据相似的样本，从而减少通过时域仿真生成离线样本所需要的耗时。

2) 提出改进的 GAN 结构，将监督回归结构引入非监督 GAN 中，以建立样本与考虑潜在事故不确定性的 CCT 之间的映射关系。这种改进结构使模型在优化过程中能够获知每轮生成样本的平均 CCT，从而为 GAN 模型评估样本生成方向的变化提供结构基础。

3) 提出改进的模型优化目标函数，使算法不仅考虑生成样本的真实性，同时考虑生成样本的分布偏移。改进后的损失函数将结合有监督结构，大量生成接近电力系统安全边界的样本，显著减少了训练 DSA 模型所需的数据量。

本章后续各小节的内容安排如下：第 2 节阐述基于卷积网络的电力系统特征提取结构；第 3 节对生成网络进行概述；第 4 节详细阐述了提出的电网安全边界样本生成算法；第 5 节展示基于 CNN 的回归模型和基于 GAN 的样本生成模型的性能；第 6 节从生成样本的真实性和临界程度两个方面，比较所提样本

生成模型与现有方法；第 7 节展示增强后的训练数据集对在线 DSA 模型性能的改善，包括所需数据大小和 DSA 准确性方面；第 8 节进行本章小结。

2.2 基于卷积神经网络的电力系统信息提取层

CNN 是一种前馈神经网络，在语音和图像识别等领域取得了卓越的性能表现。与传统的全连接神经网络相比，CNN 的一个显著优势是采用了符合生物神经元稀疏响应特性的局部连接方式，实现了神经元之间的稀疏连接和权值共享。这种设计不仅有效地保持了网络性能，同时大幅降低了网络模型的参数规模，避免了参数冗余问题。

在本章及第三、四章中，均采用 CNN 作为电气特征提取层的主干网络。该电力系统信息提取结构主要包括卷积层（Convolution Layer）、池化层（Pooling Layer）、激活层（Activation Layer），以及全连接层（Fully Connected Layer）等多个神经网络层。这些特征提取方法的应用深化了网络的层次结构，有效降低了模型过拟合的风险，同时进一步提升了神经网络对非线性电力系统信息的提取和建模能力。

本节将详细阐述基于卷积网络的特征提取技术原理和机制。同时，本节将说明引入正则化技术的优势，尤其是其在增强模型泛化能力和减轻过拟合风险方面的重要作用。由于本文第二、三、四章均基于生成对抗网络，因此下文将介绍本章及第三、四章中采用的特征提取技术。

1. 卷积层

卷积层由多个卷积核组成，每个卷积核包含权重系数和偏置。每个神经元与前一层中的多个相邻神经元连接，这些相邻区域被称为感受野，感受野的大小由卷积核定义。卷积神经网络通过共享相同的过滤器权重来实现局部连接和权值共享的特性。

卷积核以规律的方式在输入特征上进行滑动，每次在感受野内执行矩阵元素乘法求和，并加上偏置。数学计算如下：

$$Z(i, j, k) = \sum_{a=1}^m \sum_{b=1}^n \sum_{c=1}^l X(i+a-1, j+b-1, c) \cdot W(a, b, c, k) \quad (2-1)$$

其中， $Z(i, j, k)$ 是特征图的第 i 行、第 j 列、第 k 个通道的元素； m 和 n 是卷积核的高度和宽度； l 是输入数据的通道数； $W(a, b, c, k)$ 是卷积核的参数； a 和 b 分别代表卷积核在水平和垂直方向上的位置偏移； c 代表输入数据的通道索引。

卷积操作后需要加上偏置 b_k ，得到卷积层的输出 A ，即：

$$A(i, j, k) = Z(i, j, k) + b_k \quad (2-2)$$

此外,本章在学习电气数据特征时同样应用了卷积转置(ConvTranspose)操作。卷积转置也被称为反卷积(Deconvolution)或上采样(Upsampling),是卷积神经网络中常用的一种操作,用于实现特征图的上采样。与卷积类似,卷积转置通常采用参数共享的策略,以减少训练参数的数量。

卷积转置通过在输入特征图之间插入零值来扩大特征图的尺寸。该操作使用一个可学习的卷积核(转置卷积核),通过在输入特征图上滑动并执行卷积运算,生成更大的输出特征图。

数学上,卷积转置的操作可以表示为:

$$Y(i,j,k) = \sum_{a=1}^m \sum_{b=1}^n \sum_{c=1}^l Z(i+a-1,j+b-1,c) \cdot W(a,b,c,k) \quad (2-3)$$

其中, $Y(i,j,k)$ 表示卷积转置的输出特征图的第 (i,j,k) 位置的值, $Z(i+a-1,j+b-1,c)$ 是输入特征图的相应位置的值, $W(a,b,c,k)$ 是卷积转置的权重参数; m, n, l 分别表示卷积核的高度、宽度和深度, k 表示输出特征图的深度(通道数)。

2. 池化层

池化层的主要目的是通过降采样(downsampling)来减小特征图的空间尺寸,从而减少最后全连接层的参数数量,同时保留主要特征。使用池化层可以加速计算并减少过拟合。池化操作通常在卷积层后使用,常见的池化方式包括最大池化和平均池化。以下是池化层的计算公式。

1) 最大池化

对于每个池化窗口,在特定通道上选择窗口中的最大值,即:

$$Y(i,j,k) = \max_{a,b} X(s_i+a,s_j+b,k) \quad (2-4)$$

其中, $Y(i,j,k)$ 表示输出池化特征图的元素, X 是输入特征图, s_i 和 s_j 是池化窗口的步幅, (a,b) 是窗口内的相对位置, k 表示特征图的通道索引。

2) 平均池化

对于每个池化窗口,在特定通道上计算窗口中元素的平均值,即:

$$Y(i,j,k) = \frac{1}{m \times n} \sum_{a,b} X(s_i+a,s_j+b,k) \quad (2-5)$$

其中, m 和 n 是池化窗口的高度和宽度。 $Y(i,j,k)$ 表示输出池化特征图的元素, X 是输入特征图, s_i 和 s_j 是池化窗口的步幅, (a,b) 是窗口内的相对位置。

3. 激活层

激活层在神经网络中的作用是引入非线性特性,使得网络能够学习更加复杂的函数关系。激活函数通常被应用于每个神经元的输出,将线性组合的结果

映射到非线性范围内。本章基于生成对抗网络生成电网数据，采用了不同的激活函数来学习和生成非线性的电网数据。以下是本章中生成对抗网络所使用的激活函数及其公式：

1) Sigmoid 激活函数

Sigmoid 函数具有平滑的导数，将输入映射到范围在(0,1)之间，常用于二分类问题的输出层（见表 2-6）。数学表达式为：

$$\sigma(z) = \frac{1}{1 + e^{-z}} \quad (2-6)$$

2) Tanh (Hyperbolic Tangent) 激活函数

Tanh 函数将输入映射到范围(-1,1)之间，相比 Sigmoid，它的输出范围更广，对于零中心的数据有更好的表现（见表 3-1）。数学表达式为：

$$\tanh(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}} \quad (2-7)$$

3) ReLU 激活函数

ReLU 函数在输入值大于零时返回输入值，否则返回零。ReLU 存在神经元死亡问题，即在训练过程中某些神经元可能永远不会被激活，导致权重无法更新（见表 2-3，4-2，4-3）。数学表达式为：

$$f(z) = \max(0, z) \quad (2-8)$$

4) LeakyReLU 激活函数

LeakyReLU 在输入小于零时返回一个小的斜率，通过引入小的负斜率 α ，以避免 ReLU 的神经元死亡问题（见表 2-5，2-7. 3-1，3-2）。数学表达式为：

$$f(z) = \begin{cases} z & \text{if } (z > 0) \\ \alpha z & \text{otherwise} \end{cases} \quad (2-9)$$

4. 全连接层

全连接层是神经网络中最基本的层结构之一，每个神经元都与前一层的所有神经元相连接，形成了一个密集连接的结构。全连接层的引入增加了网络的灵活性，有助于捕捉输入特征之间的复杂关系。在深度学习中，全连接层通常用于网络的最后几层，将高级抽象特征映射到最终输出。由于全连接层具有较大的参数量，容易导致过拟合，因此在实践中常与其他类型的层结合使用，如卷积层、池化层等。全连接层的计算可以表示为：

$$Y = f(XW + b) \quad (2-10)$$

其中， X 是输入矩阵，每一行对应一个样本的特征； W 是权重矩阵，每一列对

应一个神经元的权重； b 是偏置向量，对应每个神经元的偏置； f 是激活函数。

5. Dropout 技术

在本章对复杂电网信息的提取中，大量采用了 Dropout 技术。Dropout 是一种用于防止神经网络过拟合的正则化技术。如图 2-1 所示，在训练过程中，Dropout 随机地将网络中的一部分神经元暂时排除。通过在每次训练迭代中随机丢弃神经元，强制网络不依赖于特定的神经元，从而减少对某些特征的过度依赖，增加了网络的鲁棒性和泛化能力。




图 2-1 在神经网络中加入 Dropout 技术图示

Fig. 2-1 An illustration of the dropout technique applied to a neural network

Dropout 公式如下：

$$Y = \frac{X \odot M}{1-p} \quad (2-11)$$

其中， Y 表示 Dropout 操作的输出， X 是输入矩阵， M 是二值掩码矩阵， $\odot$ 表示逐元素相乘， p 是丢弃概率。这个公式表示通过在输入矩阵中的某些位置乘以零，然后除以 $(1-p)$ 来实现 Dropout 操作。

6. 归一化层

归一化层在深度学习中被广泛应用，其主要目的是通过适当地对每一层的输入进行归一化，提高模型的训练稳定性和泛化性能。特别是在深层网络中，梯度的传播容易受到梯度消失或梯度爆炸的问题，而归一化层通过调整输入分布，有助于缓解这些问题，并加速网络的收敛过程。

1) 批归一化 (Batch Normalization, BN)

批归一化是一种常见的归一化方法^[118]，该方法在每个批次的训练数据中计算均值和标准差，然后对输入进行归一化，使其均值接近 0，标准差接近 1。批归一化的优势在于它有助于缓解内部协变量漂移 (Internal Covariate Shift) 的问题，使得激活函数的输入保持在较小的范围内，有助于梯度的稳定传播。通过引入可学习的缩放和平移参数，批归一化还允许网络自适应地学习每一层

的适当缩放和平移，增强了模型的表达能力。此外，批归一化还可以充当正则化的作用，减少对其他正则化技术的需求，如 Dropout。

对于输入 x ，批归一化首先计算其均值和标准差，然后通过以下公式进行归一化：

$$\hat{x}^{(k)} = \frac{x^{(k)} - \mu^{(k)}}{\sqrt{\sigma^{(k)2} + \epsilon}}, \quad z^{(k)} = \gamma^{(k)} \hat{x}^{(k)} + \beta^{(k)} \quad (2-12)$$

其中， μ 是均值， σ 是标准差， ϵ 是一个很小的常数，以避免除零错误。 k 在这里表示特征的数量或通道的数量， $x^{(k)}$ 表示第 k 个特征图（或通道）上的输入。然后，通过缩放和平移参数 γ 和 β ，得到最终的归一化输出：

$$z^{(k)} = \gamma^{(k)} \hat{x}^{(k)} + \beta^{(k)} \quad (2-13)$$

式中， γ 和 β 是学习的参数，它们允许模型在训练过程中学习适应不同分布的特征。

2) 实例归一化 (Instance Normalization, IN)

与批归一化不同，实例归一化是在通道维度上进行归一化，而不是在整个批次上^[119]。给定具有 C 个通道的输入特征图，对每个通道 c 和每个空间位置 (i, j) ，实例归一化计算过程如下：

首先，计算每个通道 c 上的均值 μ_c ，即

$$\mu_c = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W x_{ij}^{(c)} \quad (2-14)$$

式中， $x_{ij}^{(c)}$ 表示输入特征图在第 c 个通道、 (i, j) 位置上的元素， H 和 W 分别是特征图的高度和宽度。

其次，计算每个通道 c 上的方差 σ_c^2 ，即

$$\sigma_c^2 = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W (x_{ij}^{(c)} - \mu_c)^2 \quad (2-15)$$

随后，对每个通道 c 上的每个元素进行归一化，即

$$\hat{x}_{ij}^{(c)} = \frac{x_{ij}^{(c)} - \mu_c}{\sqrt{\sigma_c^2 + \epsilon}} \quad (2-16)$$

其中， ϵ 是一个小的正数，用于防止分母为零。

最后，引入可学习的参数缩放因子 $\gamma^{(c)}$ 和平移因子 $\beta^{(c)}$ 进行缩放和平移。计算公式为：

$$y_{ij}^{(c)} = \gamma^{(c)} \hat{x}_{ij}^{(c)} + \beta^{(c)} \quad (2-17)$$

由于实例归一化在单个样本通道上进行，相对于批归一化，实例归一化更适合处理样本之间分布差异较大的情况。这有助于减轻批量归一化可能引入的批量间相关性问题的。

综上所述，通过合理组合卷积层、激活层、池化层和全连接层，并选择适当的正则化技术，可以建立一种卷积框架下的电气特征提取模型。该特征提取模型能够对复杂的电网信息进行非线性处理，从而准确有效地捕捉电力系统中的关键特征。

2.3 生成对抗网络基本概述

GAN 是一种深度学习模型，如图 2-2 所示，其基本原理是通过生成器（Generator）和判别器（Discriminator）的对抗学习，同步提高生成器和判别器的性能。GAN 的最终目标是训练生成器生成更逼真的数据样本，使生成样本难以与原始样本区分。




图 2-2 GAN 的基本结构

Fig. 2-2 Basic GAN architecture

GAN 的目标可以被表述为一个极小极大问题，综合考虑了生成器和判别器的优化目标。生成器和判别器在优化过程中呈现动态博弈过程。可以由以下公式表示：

$$\min_G \max_D V(D, G) = \mathbb{E}_{x \sim P_{\text{data}}(x)} [\log D(x)] + \mathbb{E}_{z \sim P_z(z)} [\log(1 - D(G(z)))] \quad (2-18)$$

其中， $P_{\text{data}}(x)$ 和 $P_z(x)$ 分别代表真实数据和噪声数据的分布， $\mathbb{E}$ 表示期望。生成器和判别器依次迭代训练。生成器从噪声分布 $P_z(x)$ 生成数据样本，判别器评估这些生成的样本，并向生成器提供反馈。

2.3.1 判别器基本结构

判别器的任务是区分生成器生成的数据和真实数据。判别器网络的参数记为 θ_d ，其输出为输入数据的二元分类结果，判断输入数据是真实数据还是生成数据。判别器的目标是最小化生成数据被错误分类和真实数据被正确分类的损失，即：

$$\begin{aligned} \min_{\theta_d} \mathbb{E}_{x \sim p_{\text{data}}} [\text{Loss}_{\text{disc}}(\text{Discriminator}(x; \theta_d))] + \\ \min_{\theta_d} \mathbb{E}_{z \sim p(z)} [\text{Loss}_{\text{disc}}(\text{Discriminator}(G(z; \theta_g); \theta_d))] \end{aligned} \quad (2-19)$$

其中， $\text{Loss}_{\text{disc}}$ 表示判别器损失函数， x 是真实数据的样本， z 是来自噪声分布 $p(z)$ 的样本， $G(z; \theta_g)$ 是生成器的输出。

这个公式表示判别器的总体损失，由真实数据的损失和生成数据的损失两部分组成。判别器通过调整参数 θ_d 来最小化这个总体损失。判别器的目标是在对抗训练中提高对真实数据和生成数据的区分能力。

2.3.2 生成器基本结构

生成器的任务是接收一个随机噪声向量 z ，并将其映射成与真实数据分布相似的数据。生成器网络的参数记为 θ_g ，其输出为生成数据 $G(z; \theta_g)$ 。生成器的目标是最小化生成的数据与真实数据之间的差异，即：

$$\min_{\theta_g} \mathbb{E}_{z \sim p(z)} [\text{Loss}_{\text{gen}}(G(z; \theta_g))] \quad (2-20)$$

其中， Loss_{gen} 表示生成器损失函数， z 是来自噪声分布 $p(z)$ 的样本。

在这个公式中，生成器通过调整参数 θ_g 来最小化生成数据与真实数据之间的损失，从而提高生成器的性能。

GAN 网络的训练过程的伪代码如表 2-1 所示。

2.4 电网安全边界数据生成方法

本节提出了一种基于改进 GAN 结构的数据生成模型，由生成器和判别器网络组成，旨在学习高维度的电力系统数据分布，并生成大量安全边界样本。

与基础的无监督 GAN 结构不同（见图 2-2），本节提出的 GAN 模型（见图 2-3）嵌入了额外的监督结构，使模型优化过程中能够直接提供每轮生成样本的平均 CCT，从而为 GAN 模型生成边界样本提供结构基础。

2.4.1 考虑生成数据真实性的判别器损失函数

判别器 D 的目标是准确区分真实电网数据和生成电网数据，即区分生成数据 $G(z)$ 和原始（真实）数据 x 。为解决 GAN 训练过程中潜在的梯度消失问题，将公式(2-18)中的对数损失替换为平方损失^[120]，判别器 D 的损失函数定义如下：

$$\max_D \mathcal{L}_D = \mathbb{E}_{x \sim P_{\text{data}}(x)} \left[(D(x))^2 \right] + \mathbb{E}_{z \sim P_z(z)} \left[(1 - D(G(z)))^2 \right] \quad (2-21)$$

表 2-1 GAN 训练算法伪代码

Table 2-1 Pseudocode for the GAN training algorithm

GAN 训练算法步骤
输入： 学习率 η ，minibatch 大小 m ，截断参数 c ，判别器迭代次数 n_{disc} ，生成器迭代次数 n_{gen}
初始化： 初始生成器权重 θ_g 和判别器权重 θ_d
For 每轮训练迭代
For $i=0,1,\dots,n_{\text{disc}}$
从历史数据中采样大小为 m 的小批量样本： $\{x_1, x_2, \dots, x_m\}$
从噪声分布中采样大小为 m 的小批量噪声： $\{z_1, z_2, \dots, z_m\}$
计算判别器网络梯度： $\nabla_{\theta_d} L_{\text{disc}}$
更新判别器参数： $\theta_d \leftarrow \theta_d - \eta \cdot \nabla_{\theta_d} L_{\text{disc}}$
对判别器参数进行截断： $\theta_d = \text{clip}(\theta_d, -c, c)$
End For
For $j=0,1,\dots,n_{\text{gen}}$
从噪声分布中采样大小为 m 的小批量噪声： $\{z_1, z_2, \dots, z_m\}$
计算生成器网络梯度： $\nabla_{\theta_g} L_{\text{gen}}$
更新生成器参数： $\theta_g \leftarrow \theta_g - \eta \cdot \nabla_{\theta_g} L_{\text{gen}}$
End For
End For

为提高 GAN 训练的稳定性和效率，将判别器损失函数中的最大化问题转化为最小化问题，如下所示：

$$\min_D \mathcal{L}_D = \mathbb{E}_{x \sim P_{\text{data}}(x)} \left[(D(x) - 1)^2 \right] + \mathbb{E}_{z \sim P_z(z)} \left[D(G(z))^2 \right] \quad (2-22)$$

2.4.2 考虑生成样本极限切除时刻的生成器损失函数

生成器 G 接受噪声矩阵 Z 作为输入。 $Z \in R^{d \times c}$ 是一个预先定义分布的输入噪声，其中 d 表示 PMU 的数量， c 表示电气变量的数量。 $\mathbf{X}$ 反映了电力系统各节点间的电气联系，生成器的目标是学习真实数据矩阵 $\mathbf{X}$ 的潜在分布。

为了生成真实且处于 DSA 分类任务边界的临界样本，本章给 G 构建的损失函数包含两部分。第一部分，记为 $\mathcal{L}_G$ ，旨在通过考虑判别器 D 的损失值来

评估生成样本的真实程度；第二部分，记为 $\mathcal{L}_M$ ，旨在评估生成样本的临界程度。因此，生成器的总体目标是产生与原电力特征分布相似的真实样本，同时生成样本的 CCT 与系统故障清除时刻接近。 G 的损失函数表示为：

$$\min_G \mathcal{L}_G(z) + \alpha \min_G \mathcal{L}_M(z) \quad (2-23)$$

其中， α 是一个超参数（本章中通过交叉验证设置为 3），且

$$\min_G \mathcal{L}_G = \mathbb{E}_{z \sim P_z(z)} \left[D(G(z)-1)^2 \right] \quad (2-24)$$




图 2-3 面向安全边界样本生成的对抗模型优化过程及分布变化展示

Fig. 2-3 Optimization process and distribution shifting of the GAN model for security boundary data generation

为了在模型优化过程中准确评估生成样本 $G(z)$ 的 CCT，本章算法在 GAN 结构中嵌入了一个基于 CNN 的回归模型 C （见图 2-3）。回归模型 C 建立了电

气数据与 CCT 之间的映射关系。在此基础上, 使用损失函数 $\mathcal{L}_M$ 促使模型生成的运行点 CCT 与故障清除时刻接近, 即接近 DSA 安全边界的样本。具体用公式表示为:

$$\min_G \mathcal{L}_M = \frac{1}{n} \cdot \sum_{i=1}^n \left(\exp(|C(G(z_i)) - t_i|) - 1 \right) \quad (2-25)$$

式中, n 表示样本数量; t_i 表示给定的故障清除时间, 在 DSA 任务中是一个已知的值, 由电力系统中的继保动作时间决定。 $C(G(z_i))$ 和 t_i 之间的差异可以被视为样本 i 的临界程度。 $\mathcal{L}_M$ 中引入指数函数出于以下原因: 首先, 指数运算加速了优化过程; 其次, 指数函数加强了模型的非线性, 促使其捕捉电力系统中的复杂关系。

2.4.3 预测样本 CCT 的回归模型

本章研究通过计算样本 CCT 与故障清除时间之间的相对距离, 来评估其临界程度。在 DSA 中, 安全边界样本定义为其 CCT 与故障清除时间相等的样本, 而安全边界被视为安全和不安全区域的分界线^[121]。稳定运行点是指在预想故障下, 该运行点的 CCT 值大于故障清除时间。现有研究中, 基于发电机最大转子角差来定义稳定边界^[122], 但该方法会受到样本时域仿真时长以及判定系统暂态失稳的发电机最大转角差阈值的影响。而本章基于 CCT 的指标则不受这些参数的影响, 进一步增强了所提方法在生成边界样本方面的通用性。

本章构建了一个回归模型, 用于映射稳态信息与其 CCT 之间的关系。这个回归模型是 GAN 框架的重要组成部分, 用于评估 GAN 优化过程中每个生成样本的 CCT。考虑到电力系统中可能发生的多种故障, CCT 与电气信息之间的映射关系可以定义为:

$$\text{CCT} = \min_{\delta \in \Delta} C(x, \delta) \quad (2-26)$$

其中, CCT 代表该运行点的临界切除时刻, x 表示运行点的稳态信息 (包括电力系统中每条母线的有功和无功功率), Δ 表示可能发生的各种故障 (不同输电线路上的故障位置), $C(x, \delta)$ 代表运行点 x 发生故障 δ 时的 CCT。

为了最小化回归模型 C 中的预测误差, C 的目标函数可以表示为:

$$\min \mathcal{L}_C = \sqrt{\frac{1}{n} \cdot \sum_{i=1}^n |\hat{x}_i - x_i|^2} \quad (2-27)$$

其中, n 是样本数量, $\hat{x}_i$ 和 x_i 分别是预测的 CCT 和真实的 CCT。

需要注意的是，该回归模型能够以较高精度预测运行点的 CCT。然而，该模型并不适合直接预测 DSA 的稳定性。具体来说，如式(2-27)所示，该损失函数将衡量预测的 CCT 和真实 CCT 之间的欧氏距离。考虑一个真实 CCT 为 0.11s 的场景，当该模型预测的 CCT 为 0.09s 或 0.13s 时，这两个预测结果将给模型带来相同的损失值。然而，在故障清除时间为 0.1s 的情况下，这两个输出将对完全相反的 DSA 稳定结论。因此，该模型主要作为 GAN 网络中样本生成方向的引导机制，促使生成样本的 CCT 更接近故障清除时间。

2.5 算例分析

本节通过实验评估所提模型的性能。第 2.5.1 节介绍使用的原始数据集；第 2.5.2 节和第 2.5.3 节分析所提模型的性能，并评估算法中每个模块对算法精度的影响。

2.5.1 数据集构建

本章数据集基于 50 Hz 的 IEEE-39 电力系统生成，在生成过程中考虑了多种运行条件和故障场景。为确保生成场景的仿真准确性，采用 Power System Toolbox 3.0^[123]工具箱进行暂态稳定性仿真，并通过精确的时域仿真方法生成数据库。时域仿真的核心是建立描述电力系统动态的微分代数方程，刻画系统约束条件，并通过求解非线性代数网络方程计算母线相角^[124]，以保证仿真结果的准确。

所提 GAN 网络的样本空间与现有 DSA 文献相符，样本空间由电力系统的运行范围和基准运行点确定。为确保数据集样本之间具有显著差异，数据集构建时考虑了多种故障场景，保持母线电压在 0.95-1.05 p.u.的范围内^[49]，清除时间设定为 0.2s^[125]。具体的数据构建方法如表 2-2 所示。

表 2-2 数据构建方法
Table 2-2 Method of data construction

描述	
负荷	基准值的 120%逐渐降低到 80%
发电	在基准值的 120%到 80%的范围内随机生成
故障线路	依次选择线路 1-39、线路 2-3 和线路 6-5

使用特征图 $X \in R^{d \times c}$ 来表示电力系统的故障前运行点，其中 $c=2$ 表示每条母线的无功和有功功率测量值， $d=38$ 表示 IEEE-39 电力系统中的母线数（不包括平衡节点）。原始数据集包含 2000 个场景，并通过时域仿真获得相应的 CCT 值。数据集随机分成训练集和测试集，样本比例为 8:2。

2.5.2 CCT 回归模型结构和性能

本节讨论了所提回归模型 C 的结构，该模型与 GAN 框架结合使用，在评估生成样本的 CCT 时表现出较高的准确性。

为了确保 CCT 预测的可靠性，使用平均绝对百分比误差 (MAPE) 和均方百分比误差 (MSPE) 来评估模型的性能。这些指标的表达式如下：

$$\text{MAPE} = \frac{1}{n} \cdot \sum_{i=1}^n \left| \frac{\hat{x}_i - x_i}{x_i} \right| \tag{2-28}$$

$$\text{MSPE} = \frac{1}{n} \cdot \sum_{i=1}^n \left(\frac{\hat{x}_i - x_i}{x_i} \right)^2 \tag{2-29}$$

式中， n 表示数据集中样本的总数， $\hat{x}_i$ 和 x_i 分别表示第 i 个样本的预测值和真实值。

表 2-3 展示了所提回归模型的算法结构信息。该模型的架构包括卷积层、残差模块^[126]、全连接层和 Dropout^[127]，以有效捕捉电力系统中的特征分布。为了评估每个组件对整体模型性能的影响，表 2-4 中展示了相应的消融实验结果，通过保留特定组件来评估结果的准确性。与使用全连接结构相比，使用卷积模块带来了显著的模型性能提升，表明所提算法选择 CNN 作为主干网络适用于提取高维电气特征。卷积核的适应性使其能够平衡局部感受野内不同信息的贡献，从而提高了模型捕捉电气数据相关性的能力。此外，残差模块和 Dropout 的组合对提高评估准确性起到了显著作用。其中，残差模块有助于捕捉电力系统中的长距离时空依赖关系，而 Dropout 正则化技术通过在训练期间随机关闭神经元来缓解过拟合问题。综上所述，基于表 2-3 结构搭建的回归模型能够取得出色的 CCT 预测准确性。

表 2-3 回归模型结构
Table 2-3 Regression model structure

层	描述
卷积模块	[32 滤波器，卷积核尺寸 3，ReLU] × 2
残差模块 1	[64 滤波器，卷积核尺寸 3，ReLU] × 2
残差模块 2	[128 滤波器，卷积核尺寸 3，ReLU] × 2
池化层	最大池化，卷积核尺寸 2，Dropout 率 0.1
展平层	—
全连接层 1	64 滤波器，ReLU，Dropout 率 0.1
全连接层 2	32 滤波器，ReLU，Dropout 率 0.1
全连接层 3	1 滤波器，ReLU

表 2-4 采用不同结构的回归模型的性能(%)

Table 2-4 Performance of regression models with different structures (%)

卷积模块	残差模块	Dropout	MAPE	MSPE
—	✓	✓	2.93	0.30
✓	—	—	1.81	0.08
✓	✓	—	1.56	0.02
✓	✓	✓	1.38	0.02

2.5.3 边界样本生成模型结构和性能

表 2-5 和表 2-6 分别展示了所提 GAN 网络中的生成器和判别器结构。模型的设计思路是，通过相对简单的结构捕捉电力系统数据的基本特征，以准确生成电力系统样本。所提模型采用 CNN 作为主干结构，以利用电力系统数据中存在的空间依赖性。在生成器架构中，使用卷积转置层对特征图进行上采样，从而生成更高分辨率的样本。本节算法将卷积核大小设定为 1，以保持特征图的维度大小，确保每个像素能够准确反映电网信息间的时空依赖。为优化训练过程，根据交叉验证结果，将生成器和判别器的学习率分别设置为 0.0001 和 0.0002。

表 2-5 生成器结构

Table 2-5 Generator structure

层	描述
卷积转置模块 1	128 滤波器，卷积核尺寸 1，步幅 1
实例归一化层 1	128 滤波器，eps=1e-05，momentum=0.1
LeakyReLU	负斜率 0.2
批归一化层 1	128 滤波器，eps=1e-05，momentum=0.1
卷积转置模块 2	64 滤波器，卷积核尺寸 1，步幅 1
实例归一化层 2	64 滤波器，eps=1e-05，momentum=0.1
LeakyReLU	负斜率 0.2
批归一化层 2	32 滤波器，eps=1e-05，momentum=0.1
卷积转置模块 3	32 滤波器，卷积核尺寸 1，步幅 1
实例归一化层 3	32 滤波器，eps=1e-05，momentum=0.1
LeakyReLU	负斜率 0.2
批归一化层 3	32 滤波器，eps=1e-05，momentum=0.1
卷积转置模块 4	1 滤波器，卷积核尺寸 1，步幅 1
实例归一化层 4	1 滤波器，eps=1e-05，momentum=0.1
LeakyReLU	负斜率 0.01

表 2-6 判别器结构

Table 2-6 Discriminator structure

层	描述
卷积模块 1	32 滤波器，卷积核尺寸 2，步幅 1
实例归一化层 1	32 滤波器，eps=1e-05，momentum=0.1
LeakyReLU	负斜率 0.2
卷积模块 2	16 滤波器，卷积核尺寸 2，步幅 1
实例归一化层 2	16 滤波器，eps=1e-05，momentum=0.1
LeakyReLU	负斜率 0.2
全连接层	Sigmoid

本文采用 Fréchet Inception 距离（Fréchet Inception Distance，FID）指标^[128]评估所提生成器的性能。该指标通过分析最终层激活分布对比真实样本和生成样本的分布差异，FID 分数越低表示生成器生成的样本逼真程度越高。FID 计算公式为：

$$FID = \left\| \mu_r - \mu_g \right\|_2^2 + \text{tr}(\Sigma_r) + \text{tr}(\Sigma_g) - 2 \cdot \text{tr}(\sqrt{\Sigma_r \Sigma_g}) \quad (2-30)$$

式中， $\text{tr}()$ 表示矩阵的迹； (μ_r, Σ_r) 和 (μ_g, Σ_g) 分别表示真实数据分布和生成数据分布的均值—协方差对。

表 2-7 展示了 GAN 网络的消融实验结果，以评估不同结构下 GAN 模型的性能。在上述实验中，引入归一化技术以提升模型性能，如表 2-5 和表 2-6 所示。为加速模型训练并保持电气变量之间的依赖性，生成器中采用了批归一化和实例归一化。其中，批归一化有助于稳定训练过程，减少内部协变量偏移，从而加速收敛速度并提高泛化能力；而实例归一化保持了单个样本的电气依赖性，确保生成样本能够捕捉到电力系统的真实特征^[129]。此外，引入 LeakyReLU 激活函数解决了标准 ReLU 函数可能出现的零梯度问题，并加速了模型的收敛^[130]。该消融实验的结果表明，这些组件的整合能够更好地提取电力系统特征，并生成真实样本。

表 2-7 不同结构下的 GAN 模型性能

Table 2-7 Performance of GAN models with different architectures

卷积模块	实例归一化	批归一化	LeakyReLU	FID
✓	✓	—	✓	0.1954
✓	—	✓	✓	0.1782
✓	✓	✓	—	0.1526
✓	✓	✓	✓	0.1298

2.6 与现有数据生成方法的对比

本节从样本真实度和临界程度两个角度出发，展示所提算法相对于现有方法的提升。此外，第 2.6.2 节对生成样本进行直观可视化，以说明其分布靠近电力系统的安全边界。

2.6.1 生成样本的真实性和临界程度

本节验证了所提模型相对于现有方法在生成样本的真实性和临界程度方面的提升。对于生成样本的真实性评估，通过使用公式(2-30)计算 FID 分数，衡量原始数据和生成数据在电力系统中功率分布上的相似性。此外，样本 CCT 与故障清除时间（0.2s）之间的差距被视为样本的临界程度。基于此，本节将所提方法与常用的样本生成方法进行比较，包括 SMOTE^[54]、DCGAN^[60]和注意力 GAN（Self-attention GAN，SAGAN）^[131]。

表 2-8 通过对比各个模型的 FID 分数，比较了不同方法生成样本的真实程度。基于 SMOTE 生成的样本 FID 分数明显高于 GAN 结构，这可以归因于电力系统的复杂性和非线性，这使得 SMOTE 线性插值方法难以生成较为真实的电气样本。此外，相对于所提算法和 DCGAN，SAGAN 的性能相对较弱，这说明基于 CNN 的 GAN 模型具有更强的电气信息提取能力。由于 CNN 模型稀疏连接和权值共享特性，基于 CNN 的 GAN 算法训练更加稳定。综上所述，与现有方法相比，所提方法能够生成更具真实性的样本。

表 2-8 不同模型生成数据的特性

方法	FID	CCT 平均值(s)	CCT 中位数(s)
SMOTE ^[37]	0.2421	0.46	0.47
DCGAN ^[76]	0.1350	0.44	0.44
SAGAN ^[77]	0.1850	0.47	0.49
所提算法	0.1298	0.22	0.20

从表 2-8 中可见，所提方法生成数据的平均和中位数 CCT 分别为 0.22s 和 0.20s，明显区别于原始数据中的 0.46s 和 0.42s。这是由于在损失函数(2-25)的作用下，模型优化目标不仅仅是生成逼真的样本，而是在保持样本逼真程度的基础上，促使生成样本的 CCT 分布向故障清除时刻（0.2s）偏移，生成接近电力系统安全边界的样本。相比之下，DCGAN 和 SAGAN 更倾向于生成与原始数据分布相似的样本，生成样本的 CCT 值与原始数据相似。因此，基于所提方法生成的数据集包含了更多适用于 DSA 任务的临界样本，这些临界样本中包含了稳定分类的关键信息，可以提高 DSA 模型对稳定边界的刻画能力。




图 2-4 不同数据集的 CCT 密度分布：(a)原始数据集，以及使用以下方法生成的数据集：(b)SMOTE，(c)DCGAN 和(d)所提方法。

Fig. 2-4 Density distributions of CCTs for different datasets, including (a) the original dataset, and those generated with (b) the SMOTE, (c) the DCGAN, and (d) the proposed method.

图 2-4 展示了不同方法生成样本的 CCT 密度分布。可以看出，使用 SMOTE 和 DCGAN 生成的样本与原始样本分布相似。对比发现，采用所提方法生成的样本表现出显著差异，其 CCT 分布集中在 0.2s 附近，对应电力系统故障清除时间。这进一步验证了所提方法能够有效引导样本的生成方向，生成大量边界样本。

2.6.2 算法可扩展性测评与可视化：以 IEEE-9 节点系统为例

本节实验旨在直观展示所提算法生成安全边界样本的能力。为此，选择 IEEE-9 系统作为仿真系统，其在展示电气变量时不需要降维技术。与 IEEE-39 电力系统相比，IEEE-9 系统的结构更为简化，仅包含 3 台发电机，其中 1 台为平衡机组，其余 2 台发电机的功率输出能够直接在二维直角坐标轴内可视化。在构建 IEEE-9 系统的原始数据集时，设置每条母线的有功功率和无功功率在

基准值的 $\pm 10\%$ 范围内随机变化。在 2 条不同的输电线路（4-5 和 5-6）上施加三相对地短路故障，并将清除时间设定为 0.1s。




图 2-5 不同数据集下的运行点可视化对比：(a)原始数据集，

以及使用以下方法生成的数据集：(b)SMOTE，(c)DCGAN 和(d)所提方法。

Fig. 2-5 Visual comparison for different datasets, including (a) the original dataset, and those generated with (b) the SMOTE, (c) the DCGAN, and (d) the proposed method.

图 2-5 展示了系统中的两个非平衡机组，即发电机 1 和发电机 2 的有功功率输出。具体而言，图 2-5(a)展示了原始数据的分布，其中“稳定”和“不稳定”样本分别指该样本的 CCT 大于和小于故障清除时刻。如果样本 CCT 与故障清除时间的差值在 ± 0.02 秒范围内，该样本被定义为“临界运行点”，如图 2-5(a)所示，这些临界运行点集中在安全边界附近。距离安全边界较远的样本很容易被 DSA 模型识别，因为这类样本通常具有明显的不稳定或稳定特征，而边界样本则容易被 DSA 误判。如前文所述，尽管临界样本在原始数据集中占比较小，但对于训练数据驱动 DSA 分类器具有较高的的重要性。

图 2-5(b)-(d)展示了使用不同算法生成的运行点，包括 SMOTE、DCGAN 和所提算法。图 2-5(b)-(c)中生成的数据与原始数据的分布非常相似，发电机 1 和发电机 2 的输出均匀分布在原始样本空间内。然而，图 2-5(d)中的发电机功

率分布接近于图 2-5(a)中的临界运行点，并且有效地减少了远离安全边界的样本。这种分布的变化可以归因于损失函数公式(2-25)，其将生成样本的 CCT 与系统故障清除时刻之间的距离作为模型优化的惩罚损失。随着模型的迭代训练，生成样本的 CCT 逐渐接近故障清除时刻，使得模型生成了大量靠近安全边界的样本。

2.7 生成样本对 DSA 模型性能的提升

本章旨在建立一个能够生成大量边界样本的数据集生成算法。将基于该算法生成的数据集与原始样本集合并，形成一个扩充数据集，用于训练 DSA 模型，以提高在线 DSA 的准确性。为验证所提 GAN 模型生成的训练数据能有效提升 DSA 模型的准确率，本节分别使用原始数据和加入本章生成数据的样本集来训练 DSA 模型，进行对比实验。原始数据根据 2.5.1 节描述的时域仿真构建。本节测试集基于时域仿真生成，包含 300 个样本，用于评估 DSA 模型的性能。

需要注意的是，DSA 任务本质上是一个分类任务，其离线训练的样本需要带有标签。然而，使用 GAN 结构生成的样本是无标签样本，即使能够使用本章已训练的回归模型 C 来预测样本 CCT，其稳定判别仍会受到回归模型预测误差的影响，无法为生成样本提供准确的标签，如 2.4.3 节所述。

因此，本节采用深度置信网络（Deep Belief Network，DBN）建立 DSA 模型，其结构如表 2-9 所示。DBN 模型通常由堆叠的受限玻尔兹曼机（Restricted Boltzmann Machine，RBM）层和分类层组成。DBN 模型的训练集可以包含无标签样本，首先使用无标签数据进行预训练，然后使用带有标签的数据进行监督学习微调。因此，DBN 分类器能够从无标签数据中学习到相关的电气特征。

表 2-9 基于 DBN 建立的 DSA 分类模型
Table 2-9 DSA classification model based on DBN

层	描述
RBM1	32 滤波器，滤波器尺寸 3，ReLU，Dropout 率 0.1
RBM2	32 滤波器，滤波器尺寸 3，ReLU，Dropout 率 0.1
RBM3	64 滤波器，滤波器尺寸 3，ReLU，Dropout 率 0.1
RBM4	64 滤波器，滤波器尺寸 3，ReLU，Dropout 率 0.1
分类层	softmax

表 2-10 展示了不同数据集下 DSA 分类模型的性能。从表中可以看出，随着生成数据规模的增加，DSA 分类的准确性明显提高，证明无标签数据能够提升 DBN 模型对电气信息的提取能力。在总样本量固定为 800 的情况下，将

200 个无监督的边界样本加入训练集能够提升 DSA 模型的准确率，这与现有文献中边界样本在分类任务中具有更高价值的结论相符。

表 2-10 基于不同数据集训练得到的模型性能
Table 2-10 Performance of models trained on different datasets

数据集	数据集样本量	分类准确性(%)
原始数据	800	93.44
	600	92.87
	1100 (800 原始数据+300 生成数据)	96.50
扩增数据	1000 (800 原始数据+200 生成数据)	96.14
	800 (600 原始数据+200 生成数据)	95.98

综上所述，通过所提方法增强训练集，能够降低 DSA 模型对训练数据规模的需求，并能保持较高的准确性。这表明所提样本生成方法对 DSA 模型的离线训练提供了有效的数据基础。

2.8 本章小结

本章提出了一种基于生成对抗机制的临界样本生成方法。该方法将基于卷积机制的监督模型融入生成对抗结构，并提出了考虑样本与分类边界距离的损失函数，由此构建能够大量生成安全边界附近样本的生成算法。仿真结果表明，相比现有方法，该算法能够生成更为真实且靠近分类边界的样本。同时，通过对生成样本的直观可视化，展示了这些样本的分布集中在电力系统安全边界附近。最后，通过所提方法增强训练集，能够减少 DSA 模型对训练数据量的需求，并保持较高的分类准确性，证明生成的样本能够提升 DSA 模型对安全稳定知识的学习和提取能力。

第3章 面向暂稳评估任务的临界失稳样本生成方法

3.1 引言

基于数据驱动的暂态稳定评估 (Transient Stability Assessment, TSA) 模型需要大量失稳样本来学习系统的失稳特征。同时, 训练样本中失稳和稳定样本的比例不均会引发 TSA 模型的类别不平衡问题^[61, 132]。因此, 在实际应用中, 需要使用数据生成算法生成大量失稳样本以提升 TSA 模型的评估性能。

第二章旨在生成安全域下的安全边界样本, 并不考虑所生成的边界样本是稳定或失稳, DSA 中样本为故障发生前的稳态数据。而本章生成稳定域下的临界失稳样本, TSA 根据故障清除后的信息训练, 由于 PMU 历史记录中失稳场景较为少见, 因此需要使用数据生成方法增加 TSA 训练集中的失稳样本。

如前文所述, 基于 GAN 的生成方法被广泛用于生成失稳样本, 以解决数据集中样本不均衡的问题。然而, 如现有文献[49]中指出, TSA 模型对失稳时刻较长 (故障清除到失稳发生的时间间隔较长) 的失稳样本进行评估时准确率较低, 因为这些样本在故障清除时刻的失稳特征并不明显, 呈现出临界失稳状态。其中, 失稳时刻是指电力系统发电机最大转角差等于 360° 的时刻。

为提升 TSA 模型的准确性, 本章提出了一种基于 GAN 的失稳样本生成模型。该模型能够生成大量具有更长失稳时刻的样本, 即扩充原始数据分布的尾部数据。本章修改了现有生成模型的算法结构和算法优化目标。具体来说, 本章建立了生成样本与失稳时刻之间的有监督回归模型, 并提出考虑样本失稳时刻的损失函数。在模型优化过程中, 模型通过倾向学习失稳时刻较长的临界失稳样本, 使模型更深入地学习失稳特征, 从而生成更真实的失稳数据。仿真结果表明, 通过将所提算法生成的失稳数据加入原样本集合, 解决了原数据集失稳/失稳样本比例不均衡导致的 TSA 模型分类不平衡问题, 并提升了 TSA 模型对临界失稳样本的识别能力, 最终提高 TSA 模型的准确性。本章的主要贡献如下:

1) 为了解决数据集中失稳/稳定样本比例不平衡的问题, 本章提出了一种基于 GAN 的样本生成方法, 通过扩充失稳样本集, 以解决 TSA 分类器中的分类不平衡。

2) 与传统 GAN 模型不同, 所提方法修改了 GAN 网络的损失函数, 促使模型生成大量具有更长失稳时刻的失稳数据, 增强 GAN 模型对失稳特征的学习和提取能力。

3) 所提 GAN 模型的训练过程中需要获知生成样本的失稳时刻, 但生成样本为故障清除时刻电气信息, 样本失稳时刻难以直接获取。因此, 本章在 GAN 结构中构建了基于 CNN 的监督结构, 使模型能够获知每轮迭代生成样本的平均失稳时刻。结合修改后的损失函数, GAN 模型能够生成大量符合需求的失稳样本, 最终提升 TSA 模型的性能。

本章后续各小节的内容安排如下: 第 2 节详细介绍了所提出的算法; 第 3 节从距离指标和特征相关系数两方面分析了生成样本的真实性, 并将所提算法与现有方法进行了比较; 第 4 节验证了所提方法对在线 TSA 任务的提升作用; 第 5 节验证了所提算法对大规模电力系统的适用性; 第 6 节进行本章小结。

3.2 基于生成对抗结构的失稳样本生成模型

本节提出一种基于 GAN 的失稳样本生成模型, 旨在解决 TSA 任务中失稳/稳定样本比例不平衡的问题。与现有的生成算法不同, 所提 GAN 模型生成的失稳数据在失稳时刻上分布更均衡。

3.2.1 失稳样本生成模型的总体目标函数

GAN 结构由两个深度神经网络组成, 即生成器 G 和判别器 D , 旨在学习高维度的数据分布。GAN 的目标可以被表述为一个极小极大问题, 最终生成与原始分布相似的样本, 如 2.3 节所述。

GAN 网络的总体训练目标函数如下所述:

$$\min_G \max_D V(D, G) = \mathbb{E}_{x \sim P_{\text{data}}(x)} [\log D(x)] + \mathbb{E}_{z \sim P_z(z)} [\log(1 - D(G(z)))] \quad (3-1)$$

其中, $P_{\text{data}}(x)$ 和 $P_z(x)$ 分别代表真实数据和噪声数据的分布, $\mathbb{E}$ 表示期望。

3.2.2 考虑生成数据真实性的判别器损失函数

判别器 D 将 $G(z)$ 作为输入, 旨在判断生成数据和真实数据的真伪, 即区分生成数据 $G(z)$ 和真实数据 x , 如 2.4.1 节所述。

判别器的损失函数如下所示:

$$\min_D \mathcal{L}_D = \mathbb{E}_{x \sim P_{\text{data}}(x)} \left[(D(x) - 1)^2 \right] + \mathbb{E}_{z \sim P_z(z)} \left[D(G(z))^2 \right] \quad (3-2)$$

3.2.3 考虑分布偏移的失稳样本生成器

生成器 G 将噪声矩阵 $\mathbf{Z}$ 作为模型输入。 $\mathbf{Z} \in R^{d \times c}$ 是在输入噪声变量上定义的先验分布。其中, d 和 c 分别代表 PMU 的数量和电气变量的数量。

生成器中的损失函数 $\mathcal{L}_G$ 评估了生成器生成逼真数据的能力。基准生成器损失函数如下：

$$\min_G \mathcal{L}_G = \mathbb{E}_{z \sim P_z(z)} \left[D(G(z) - 1)^2 \right] \quad (3-3)$$

综上所述，式(3-1)表示生成器和判别器之间的对抗性训练。具体而言，在传统 GAN 中，判别器和生成器的目标分别由公式(3-2)和(3-3)引导。这个对抗性过程鼓励生成器产生更逼真的样本。

在基础 GAN 结构中，生成样本的分布通常与原始数据相似。然而，本章中不仅致力于生成逼真的样本，更希望生成的样本具有不同于原始数据的分布，即生成更多具有较长失稳时刻的失稳样本。正如文献[49]中指出，这类样本在原始数据集中较为罕见，TSA 对这类样本的识别能力不足。

为了解决这一问题，与传统的生成器损失 $\mathcal{L}_G^{\text{benchmark}}$ [在式(3-3)中]不同，本章在生成器中建立的损失函数包含两部分。生成器的目标考虑了样本的逼真性以及失稳时刻分布的变化，如下所示：

$$\min_G \mathcal{L}_G = \mathcal{L}_G^{\text{benchmark}}(z) + \alpha \mathcal{L}_M(z) \quad (3-4)$$

其中， α 是一个超参数（本章中通过交叉验证设置为 0.7）。因此，在本章中，判别器与生成器分别基于目标函数(3-2)和(3-4)交替训练。

为了生成失稳时刻较长的样本，在损失函数(3-4)中， $\mathcal{L}_M$ 评估生成样本的平均失稳时刻与原始数据中最大失稳时刻之间的距离。损失函数 $\mathcal{L}_M$ 的公式表示为：

$$\min_G \mathcal{L}_M = \left| \frac{1}{m} \sum_i^m C(G(z)) - \max_i^m C(x) \right|^2 \quad (3-5)$$

其中， m 表示失稳样本的总量。 C 是一个经过训练的回归映射，用于预测生成样本 $G(z)$ 的平均失稳时刻。换言之，公式(3-5)在数据生成过程中充当惩罚项，鼓励 G 在迭代优化中生成具有更长失稳时刻的样本。

由于电力系统特征的复杂性，难以直接计算失稳样本的失稳时刻。然而，在公式(3-5)中， C 中的映射可以通过建立一个样本与失稳时刻之间的回归模型实现，如图 3-1 所示，该回归模型能够被整合到 GAN 结构中。需要注意的是，模型 C 的训练独立于 GAN 网络训练。因此，在 GAN 网络训练期间， C 模型的内部参数固定，即 $\max_i^m C(x)$ 保持不变。




图 3-1 面向失稳样本生成的对抗生成模型优化过程

Fig. 3-1 Optimization process of the adversarial generative model for unstable sample generation

在训练过程中，使用早停止（early stopping）技术来监控模型在测试集上的性能，并在 $\mathcal{L}_G$ 开始增加时停止训练，以确保生成样本的真实性，并避免模型训练的过拟合问题。

模型 C 的损失函数为：

$$\min \mathcal{L}_C = \sqrt{\frac{1}{n} \cdot \sum_{i=1}^n |\hat{x}_i - x_i|^2} \tag{3-6}$$

其中， n 是失稳样本的数量， $\hat{x}_i$ 和 x_i 分别表示预测和真实的失稳时刻。

回归模型 C 是一个结合了 CNN 和注意力模块的模型。具体而言，模型 C 通过非局部模块^[133]在提取特征时引入注意力机制，用于捕捉样本之间的全局

依赖关系，从而有效增强了算法的泛化能力。回归模型 C 中的注意力机制可以定义为：

$$\mathbf{y}_i = \frac{1}{N} \sum_{j=1}^N f(\mathbf{x}_i, \mathbf{x}_j) g(\mathbf{x}_j) \quad (3-7)$$

其中， N 表示电力系统中安装的 PMU 数量， i 和 j 分别表示 $\mathbf{x}$ 和 $\mathbf{y}$ 中不同电气变量的索引， $g(\mathbf{x}_j) = \mathbf{W}_g \mathbf{x}_j$ 且 $\mathbf{W}_g$ 是一个权重矩阵， $\mathbf{y}$ 是输出特征图。函数 f 将两个位置的特征图作为输入并生成一个标量，表示为：

$$f(\mathbf{x}_i, \mathbf{x}_j) = \theta(\mathbf{x}_i)^H \phi(\mathbf{x}_j) \quad (3-8)$$

其中， $\theta(\mathbf{x}_i) = \mathbf{W}_\theta \mathbf{x}_i$ ， $\phi(\mathbf{x}_j) = \mathbf{W}_\phi \mathbf{x}_j$ ， $\mathbf{W}_\theta$ 和 $\mathbf{W}_\phi$ 是可学习的权重矩阵。 θ ， ϕ ， g 为卷积运算。

3.3 算例分析

本节通过多个实验对所提模型的性能进行评估分析。第 1 小节详细介绍了数据集合的构建规则；第 2 小节展示了模型的性能，并讨论算法中每个模块对于模型性能的影响；第 3 小节从空间相关性角度分析了生成样本的真实性；最后，第 4 小节与现有模型进行对比，证明了所提算法生成的数据在真实性和失稳时刻分布上的改进。

3.3.1 样本集数据

原始数据集基于 50 Hz 的 IEEE-39 电力系统生成，该数据集考虑了多种运行条件和故障场景。数据集生成的时域仿真工具为 Power System Toolbox 3.0^[123]，仿真时长设定为 10 秒。所提 GAN 网络的样本空间与现有 TSA 分类器模型的样本空间保持一致，样本空间由电力系统的运行范围和基准运行点确定。本章节所采用的特征图为 $Z \in R^{d \times c}$ ，用于捕捉电力系统的空间动态，表示在故障清除时刻从 c 个发电机节点上收集的 d 个电气变量。在本节研究中， d 设定为 3， c 设定为 10，对应于 IEEE-39 电力系统中 10 个发电机节点上的 3 个电气变量，包括有功功率、电压幅值和相角。

为确保数据集样本具有显著差异，数据集构建时考虑了多种故障场景。具体方案为，设置负荷在 120% 到 80% 的范围内随机生成，发电量从额定运行水平的 120% 逐渐降至 80%^[49]，并确保母线电压在 0.95-1.05 p.u. 范围内。此外，分别在输电线的三个不同位置（输电线长度的 25%，50% 和 70% 处）设置三相接地短路故障^[134]。数据集包含 12000 个样本，其中失稳样本 4068 个，记录失

稳样本的失稳时刻。样本失稳判定标准被仿真时刻内发电机之间最大角度差不超过 360° [49]。在训练回归模型 C 和所提 GAN 网络时，仅使用失稳样本。数据集随机分成训练集和测试集，样本比例为 8:2。

3.3.2 模型结构和性能

表 3-1 和表 3-2 分别展示了所提 GAN 模型的生成器结构和判别器结构。所提 GAN 模型和回归模型 C 均基于 CNN 架构设计。考虑到电力系统节点之间的空间关系类似于图像数据中的空间关系[49]，本章采用 CNN 作为主干网络提取电气特征。在生成器中采用卷积转置操作，卷积核大小设为 1，如 3.3.1 节所述，特征图中的每个像素为某个特定的发电机节点信息，而不同发电机之间的关系决定了电力系统的稳定性。因此，采用 1×1 卷积核能够在像素级别上保留电气信息，这对捕捉发电机的动态特性至关重要。

表 3-1 生成器结构

Table 3-1 Generator structure

层	描述
卷积转置模块 1	40 滤波器，卷积核尺寸 1，步幅 1
实例归一化层	—
LeakyReLU	负斜率 0.2
卷积转置模块 2	1 滤波器，卷积核尺寸 1，步幅 1
tanh	—

表 3-2 判别器结构

Table 3-2 Discriminator structure

层	描述
卷积模块 1	32 滤波器，卷积核尺寸 2，步幅 1
实例归一化层 1	—
LeakyReLU	负斜率 0.2
卷积模块 2	64 滤波器，卷积核尺寸 2，步幅 1
实例归一化层 2	—
LeakyReLU	负斜率 0.2
卷积模块 3	128 滤波器，卷积核尺寸 2，步幅 1
实例归一化层 3	—
LeakyReLU	负斜率 0.2
卷积模块 4	16 滤波器，卷积核尺寸 2，步幅 1
Sigmoid	—

本节采用 FID 评估生成样本的真实程度^[128]，公式如下：

$$\text{FID} = \left\| \mu_r - \mu_g \right\|_2^2 + \text{tr}(\Sigma_r) + \text{tr}(\Sigma_g) - 2 \cdot \text{tr}(\sqrt{\Sigma_r \Sigma_g})$$

(3-9)

其中， $\text{tr}()$ 表示矩阵的迹。 (μ_r, Σ_r) 和 (μ_g, Σ_g) 分别是真实分布和生成分布的均值—协方差对。

为了研究不同模型组件的影响，表 3-3 中通过删除特定组件来获得不同模型结构的 FID 分数。表 3-3 展示了两种情况下的模型性能：第一种情况下，采用无污染的失稳数据作为训练数据；第二种情况下，考虑到 PMU 现场数据中的数据污染^[49]，在训练数据集中引入噪声和随机数据缺失来模拟 PMU 历史数据，以评估模型对 PMU 记录中数据污染的鲁棒性。在后一种情况下，根据 IEEE 标准^[135]和中国电网的历史运行数据^[71]，测量噪声小于其实际值的 1%，缺失率设置为 10%。在这两种情况下，将生成的样本与无污染样本进行比较，得出 FID 分数。需要注意的是，表 3-3 中对卷积模块的移除测试仅在判别器中进行，以保留生成器中样本的维度。

表 3-3 不同结构下的 GAN 网络性能
Table 3-3 GAN network performance with different architectures

训练数据	卷积模块	实例归一化层	LeakyReLU	FID
无污染数据	✓	—	✓	0.1375
	—	✓	✓	0.1291
	✓	✓	—	0.1250
	✓	✓	✓	0.0749
污染数据	✓	—	✓	0.2728
	—	✓	✓	0.2015
	✓	✓	—	0.1613
	✓	✓	✓	0.1075

如表 3-3 所示，通过引入实例归一化层，降低内部协变量转移，从而实现了更稳定的训练。实验结果表明，去除实例归一化层会明显降低模型生成真实样本的能力。此外，在去除 LeakyReLU 的测试中，模型性能明显下降。LeakyReLU 能够有效避免 ReLU 函数中的零梯度问题，并加速模型收敛^[130]。综上，在污染和非污染的两种情况下，所提 GAN 结构均能够有效提取电气特征并生成逼真样本。

监督回归模型 C 用于建立失稳时刻与电气变量之间的映射关系，如图 3-1 所示。为验证引入模型 C 能够提升生成样本的逼真程度，表 3-4 比较了真实样本和生成样本的 FID 值（FID 值越低越好）。由于本章旨在生成失稳时刻较长的样本集，因此重点关注评估原始数据集中失稳时刻大于 4 秒的罕见场景；这类失稳场景仅占原始失稳数据集的 17%，但对于 TSA 任务至关重要。

表 3-4 的结果表明，在 GAN 结构中嵌入 C 模块可以增强生成样本的真实程度。由于模型 C 会促使 GAN 生成失稳时刻更长的样本，使生成器逐渐将数据生成场景移向原始失稳时刻分布的尾部场景。对于这类场景，故障清除时刻的失稳特征通常不明显，但通过 GAN 网络中的博弈过程，生成器能够学习到更深入的失稳特征。综上所述，本节验证了所提出的方法能够使生成器 G 生成高度逼真的失稳样本，特别是在涉及原始数据集中的罕见场景时。

表 3-4 在有/无 C 模块嵌入时 GAN 网络生成数据的真实程度对比

Table 3-4 Authority level comparison of the GAN-generated data with/without C module

算法	FID（尾部场景）	FID（全部场景）
含 C 嵌入的 GAN 模型	0.0820	0.0749
无 C 嵌入的 GAN 模型	0.2995	0.1120

此外，如公式(3-4)和(3-5)所示，建立一个准确预测失稳时刻的回归模型对于所提 GAN 模型是必不可少的。回归模型的性能通过计算真实失稳时刻与预测失稳时刻之间的 MAPE 进行评估，计算方式为：

$$MAPE = \frac{1}{N} \cdot \sum_{i=1}^N \left| \frac{\hat{x}_i - x_i}{x_i} \right| \tag{3-10}$$

其中，N 是失稳样本的数量， $\hat{x}_i$ 和 x_i 分别是预测的失稳时刻和真实失稳时刻。

如表 3-5 所示，回归模型 C 采用多个模块构建，包括卷积模块、非局部模块和残差模块^[126]。

表 3-5 C 模型的结构

Table 3-5 Structure of the model C

层	描述
卷积模块 1	[32 滤波器，卷积核尺寸 3，ReLU] × 2
池化层 1	最大池化，卷积核尺寸 2
残差模块 2	[64 滤波器，卷积核尺寸 3，ReLU] × 2
池化层 2	最大池化，卷积核尺寸 2
非局部模块 2	C'=32
残差模块 3	[128 滤波器，卷积核尺寸 3，ReLU] × 2
池化层 3	最大池化，卷积核尺寸 2
非局部模块 3	C'=64
全连接层 1	滤波器数量 64
全连接层 2	滤波器数量 32
全连接层 3	滤波器数量 1

表 3-6 展示了每个模型组件在回归任务中的贡献。结果显示，残差模块和非局部模块都提升了模型的性能。通过非局部模块引入注意力机制，显著提升

了模型性能。在本章中，样本特征图中的每个像素都代表着发电机节点的信息，而不同发电机之间的相角差与失稳时刻相关，非相邻像素之间的信息交互对于确定失稳时刻十分重要。如式(3-7)所示，注意力计算能够无视特征图中的相对距离运算，促进电气信息的提取^[133]。此外，PMU 现场数据污染增加了失稳时刻的预测难度，而非局部模块中的注意力计算会鼓励模型避开信息的缺失位置^[133]，从而增强模型对失稳时刻预测的鲁棒性。

表 3-6 不同结构下的回归模型对比

Table 3-6 Comparison of regression models under different structures				
训练数据	卷积模块	残差模块	非局部模块	MAPE (%)
无污染数据	✓	—	—	3.32
	—	✓	✓	2.38
	✓	✓	—	1.62
	✓	✓	✓	0.94
污染数据	✓	—	—	3.51
	—	✓	✓	2.42
	✓	✓	—	1.81
	✓	✓	✓	0.99

3.3.3 生成样本的真实程度分析

本节旨在验证生成样本的真实性，即通过相关性分析评估所提模型是否保持电气变量的内在时空关系。如第 3.2.3 节所述，特征图 $Z \in R^{d \times c}$ 中的每个像素代表特定发电机的电气测量数据。因此，本节将验证生成样本和原始样本中的各个母线之间存在类似的相关性。相关系数的计算公式为^[136]：

$$r(x,y)=\frac{\sum_{j=1}^k(x_j-\bar{x})(y_j-\bar{y})}{\sqrt{\sum_{j=1}^k(x_j-\bar{x})^2\sum_{j=1}^k(y_j-\bar{y})^2}}$$

(3-11)

其中， $\bar{x}$ 和 $\bar{y}$ 分别是电气变量 x 和 y 的样本均值。 $r(x,y)$ 衡量了母线 j 与电力系统中其余母线之间的相对相关性。

图 3-2 展示了原始样本和生成样本中的相关性。对比发现，两者结果高度相似，表明所提出的方法能够有效捕捉原始样本中存在的潜在时空相关性，反映了电力系统的物理约束。此外，与电压幅值相关性相比，角度相关性呈现出更高的相似性。这可能是因为电力系统的暂态稳定特征与发电机的角度差有更强的相关性，导致模型主要关注学习相角信息而非电压信息。




图 3-2 原始和生成样本中多个变量之间的相关性。(a)-(b): 不同发电机的相角相关性;
(c)-(d): 不同发电机的电压幅值相关性。

Fig. 3-2 Correlations between multiple variables in the original and generated samples.
(a)-(b): phase angle correlation of different generators; (c)-(d): voltage amplitude correlation of different generators.

3.3.4 与现有数据生成方法的对比

为了评估所提方法的有效性, 将其与常用的数据生成技术进行比较, 包括 SMOTE^[54]、标准 GAN^[59]和 DCGAN^[60]。所有方法都使用原始数据集中的失稳样本来生成大量失稳数据, 以解决 TSA 模型的分​​类不平衡问题。

表 3-7 对比了不同方法生成样本的真实性。其中, SMOTE 生成样本的 FID 分数明显高于 GAN 生成的样本。这可能是因为非线性电力系统模型的复杂性, 使得线性插值方法难以生成高度真实的样本。此外, 在生成原始数据尾部场景时, 现有文献中使用的 GAN^[59, 60] 结构生成的样本真实性较差。由于原始数据集中的样本分布极不均匀, 这些 GAN 网络更倾向于提取数据中比例较大的样本, 以快速降低损失函数, 因此对尾部样本的挖掘不足。相比之下, 所提出的方法不仅在整体上生成更逼真的数据, 而且在生成尾部数据方面明显优于其他算法。

表 3-7 基于不同方法生成样本的真实程度

Table 3-7 Realism comparison of generated samples based on different methods

算法	FID（尾部场景）	FID（全部场景）
所提算法	0.0820	0.0749
SMOTE ^[54]	0.4210	0.1552
标准 GAN ^[59]	0.3109	0.1266
DCGAN ^[60]	0.3082	0.1248

在暂态稳定性评估任务中，数据集的多样性可以通过失稳时刻的分布来反映。图 3-3 展示了在线路 19-33 上发生三相接地短路故障的训练数据集。其中图 3-3（a）和（b）展示了故障清除时刻的发电机相角、电压幅值和有功输出，故障分别为发生于线路 19-33 的 25%和 50%处。图 3-3(c)将 54 个样本的故障清除时刻状态量以失稳时刻逐渐增加的顺序通过 RGB 图像展示，其中，RGB 图像的三个通道分别对应故障清除时刻的发电机相角、电压幅值和有功输出。图 3-3(c)的可视化结果显示，随着失稳时刻的增加，电力系统故障清除时刻的失稳特征呈现出明显的规律性变化，这说明基于故障清除时刻电气状态量预测失稳时刻是可行的，这项结论支持了回归模型 C 的构建。此外，为展示所提方法对 TSA 模型性能的增强，本章使用的训练集与现有数据驱动 TSA 方法一致 [49]。

如图 3-3(d)所示，原始数据中的失稳时刻呈现长尾分布。失稳时刻较长的样本位于分布的尾部，代表原始数据集中的罕见事件。较长的失稳时刻意味着 TSA 分类器较难识别该样本在故障清除时刻的失稳特征。原始数据中此类情景的稀缺性降低了 TSA 分类器的识别能力。作为具体示例，图 3-3(a)展示了场景 1 在故障清除时刻的发电机变量。在这种情况下，电力系统表现出非周期性失稳特性，失稳时刻较短，系统在第一或第二摆动中失去同步，如图 3-4 所示。相对地，图 3-3(b)展示了场景 2 具有较长系统失稳时刻的振荡性不稳定特征。

图 3-4 展示了不同生成数据集中失稳时刻的分布。对比算法生成的样本失稳时刻与原始数据较为相似，主要分布在 4s 内。然而，如图 3-4(b)所示，与其他方法相比，所提方法生成的样本失稳时刻有明显的变化。通过构建有监督结构以及采用损失函数(3-5)，模型生成了大量失稳时刻较长的样本。因此，与原始数据库相比，所提方法改变了原样本中失稳时刻的长尾分布，使 TSA 模型的训练集合中包含了更多失稳时刻较长的失稳样本。

3.4 所提数据增强算法对暂稳评估模型增强的验证和分析

在现代电力系统中，区域电网互联和电子元件的广泛应用对传统的暂态稳定性评估方法提出了挑战。因此，现有研究发展了基于数据驱动的 TSA 方法，

以提供对电力系统暂态稳定的准确预测^[49, 50, 82]。为了进一步提高数据驱动 TSA 方法的准确性，本节验证了基于所提方法生成的数据能够提升 TSA 模型的准确性，从而增强电力系统的安全性和稳定性。




图 3-3 (a)故障清除时刻的样本，在 0.72 秒后失稳，即失稳时刻为 0.72 秒，(b)失稳时刻为 6.74 秒的样本，(c)线路 19-33 故障下根据失稳时刻增长排序的样本 RGB 可视化结果，(d)子图(c)中样本失稳时刻的长尾分布

Fig. 3-3 (a) A sample at fault clearance, losing stability 0.72 seconds later, i.e., with an instability moment of 0.72 seconds. (b) A sample with an instability moment of 6.74 seconds. (c) RGB visualization of samples sorted by instability moment growth under the line 19-33 fault. (d) The long-tailed distribution of instability moments for samples in (c).




图 3-4 不同方法生成增强样本集的对比

Fig. 3-4 Comparison of augmented sample sets generated by different methods

为了更全面地展示所提方法对 TSA 分类模型的提升，本节采用了不同的数据方案训练三种不同的 TSA 模型，TSA 模型分别基于 CNN^[49]、SVM^[50]和 DBN^[82]算法。本章使用 DCGAN 和所提算法增强原始数据，两种方法均生成

了 4000 个失稳样本，因此 TSA 训练集中稳定和失稳样本的比例近似平衡，如第 3.3.1 节所述。TSA 分类结果在测试集上展示，并对比了有和无 PMU 噪声影响下的测试结果。

如表 3-8 所示，基于原始样本集训练的 TSA 分类准确率相对较低。在这种情况下，训练集中失稳样本和稳定样本的数量不平衡，导致模型对失稳样本的识别能力不足，更容易将失稳样本错误预测为稳定样本。相比采用 DCGAN 增强样本，本章所提的数据增强技术显著提升了 TSA 分类性能。此外，对比可知 PMU 现场污染会降低 TSA 分类器的准确性。然而，通过所提算法增强训练样本集合，TSA 分类器会表现出更强的鲁棒性。这可以归因于样本集分布的改变，使得模型在识别失稳的早期信号方面具有更优越的性能，如图(3-4)所示。这验证了所提方法对于暂稳评估任务的必要性。

表 3-8 不同训练集合下多种 TSA 分类器准确率对比(%)

Table 3-8 Accuracy comparison of TSA classifiers with different training sets (%)

测试样本	训练样本	暂稳分类模型		
		CNN	SVM	DBN
无污染数据	原样本集合	98.08	97.15	97.54
	增强样本集合—DCGAN	98.25	97.22	97.58
	增强样本集合—所提方法	99.73	97.33	97.98
污染数据	原样本集合	97.61	95.76	97.01
	增强样本集合—DCGAN	98.01	96.10	97.32
	增强样本集合—所提方法	99.67	96.28	97.85

为了进一步证明所提算法对 TSA 分类器的性能改进，以下分析了分类器中 softmax 分类层的输出预测概率，该概率反映了分类器对其预测的置信水平^[137]。具体而言，使用 softmax 函数可以获得输入 $\mathbf{X}^{(i)}$ 被识别为类 j 的概率，其表达式为：

$$P(y^{(i)} = j | \mathbf{X}^{(i)}) = \frac{e^{\theta_j^T \mathbf{X}^{(i)}}}{\sum_{l=1}^k e^{\theta_l^T \mathbf{X}^{(i)}}} \quad (3-12)$$

其中， $y^{(i)}$ 是输入 $\mathbf{X}^{(i)}$ 的标签， θ_j 是分类 j 的参数向量， $P(y^{(i)} = j | \mathbf{X}^{(i)})$ 是输入 $\mathbf{X}^{(i)}$ 被识别为类 j 的概率， k 是类的数量。因此， $\mathbf{X}^{(i)}$ 被预测为概率最高的类别。当某个类别的输出显著高于其他类别时，可认为该预测更具有可信度。

图 3-5 展示了 TSA 分类器对测试集中 300 个失稳测试样本的预测概率，即每个样本在经过 TSA 分类层的 softmax 函数后得到该样本的失稳预测概率，图 3-5 中将这 300 个样本按照失稳概率降序排列。如图 3-5 所示，原始数据训练的模

型无法正确识别某些失稳特征不明显的样本，而基于增强数据训练的 TSA 模型可以识别并正确分类这些漏判样本。此外，相较于原始 TSA 模型，基于增强数据训练的 TSA 模型能够输出更高的失稳概率，这展示了该模型对失稳样本的识别能力更强。这也进一步验证了所提方法生成的样本有助于 TSA 模型学习暂稳特征，提升了 TSA 模型的性能。




图 3-5 基于不同训练数据的 TSA 模型分类概率输出

Fig. 3-5 Classification probability output of TSA models based on different training datasets




图 3-6 IEEE-39 系统中 TSA 分类器在(a)原始数据和(b)增强数据上的分类可视化

Fig. 3-6 Classification visualization of TSA classifier in the IEEE-39 power system on (a) original and (b) augmented data

图 3-6 通过 t-SNE 对分类器最末端的全连接层特征进行了可视化。从图 3-

6(a)可以看出,不同标签的样本之间存在重叠,表明分类器无法有效区分稳定和失稳样本。然而,在应用了所提方法增强训练集后,图 3-6(b)中不同标签数据之间的距离相对增加,验证了所提方法对 TSA 模型性能的提升。

3.5 算法可拓展性测评:以 Polish-2383 节点系统为例

3.5.1 测试系统与数据生成

本节将所提方法应用于一个规模更大、系统更复杂的实际电力系统,即 Polish-2383 节点系统。该系统共有 2383 个母线、2896 条线路,327 个发电机和 1561 个负荷。系统基本潮流数据根据该系统在 1999-2000 年冬季高峰期整理而成^[138]。该算法下的特征图为 $Z \in R^{d \times c}$,用于捕捉电力系统的空间动态。 d 设置为 3,表示故障清除时刻的电气变量,包括有功功率、电压幅值和相角。本章中采用特征选择方法将 c 设置为 45,即选择 2383 个母线中最重要的 45 条母线。在 CNN 模型的基础上使用 LIME 技术进行降维,降维原因是该系统的发电机数量较多,高维度特征中的冗余信息会导致模型在有限数据上过度拟合,从而降低模型的泛化性能。在 3.5.1 节增加说明,该算例原始样本量为 30000,其中包含稳定场景 22843 个,失稳场景 7157 个。在训练回归模型和所提 GAN 网络时,仅使用失稳样本生成失稳场景 5000 个。

3.5.2 数值测试结果分析

如表 3-9 所示,相比于表 3-7 中展示的小型电网系统,所提模型在大规模电力系统中生成的数据真实性较差。这一现象是因为大电力系统本身具有更复杂的空间关联性,并且降维操作对电力系统原始信息造成了一定的损失,从而降低了模型对非线性电力系统模型的学习能力。尽管如此,模型仍能够大量生成失稳时刻较长的样本,这表明所提方法中对损失函数和回归监督结构的改进,在特征图增大后仍然有效,表明了所提方法在大规模电网情境下的适用性。同时,所提模型在污染数据和非污染数据下的性能相近,这证实所提算法结构对大型电网非线性动态特性的提取仍然有效,能够呈现出良好的鲁棒性。综上所述,表 3-9 的结果充分证明了所提方法在大电网中的有效性,为模型在实际应用中的可信性提供了一定支持。

表 3-9 算法生成失稳数据的真实性和失稳时刻偏移

Table 3-9 The authenticity and the instability moment shifting of instability data generated by the algorithm

数据	FID	生成数据与原始数据 平均失稳时刻差(s)
无污染数据	0.1905	5.92
污染数据	0.1959	6.01

表 3-10 展示了使用不同训练数据时，CNN 暂稳分类器对无污染和有污染数据的性能对比结果。相较于使用原始样本集合，使用增强样本集合时，CNN 分类器在污染和非污染场景下的暂稳性能均有提升。这一方面由于引入失稳样本平衡了模型的分类偏向，另一方面，新加入的样本中包含大量失稳时刻较长的失稳样本，促使模型更深入地学习失稳特征。综上所述，表 3-10 的结果表明所提出的数据增强方法在大型电力系统失稳识别中依然有效。

表 3-10 不同训练集合下分类器准确度对比(%)

Table 3-10 Accuracy comparison of classifier performance with different training sets (%)

测试样本	训练样本	CNN 分类器
无污染数据	原样本集合	95.31
	增强样本集合—所提方法	97.08
污染数据	原样本集合	94.95
	增强样本集合—所提方法	96.88




图 3-7 Polish-2383 节点系统中 TSA 分类器在(a)原始数据和(b)增强数据上的分类可视化
Fig. 3-7 Classification visualization of TSA classifier in the Polish-2383-node power system on (a) original and (b) augmented data

图 3-7 对分类器最末端全连接层特征进行了 t-SNE 可视化。从图 3-7(a)可以看出，失稳样本和稳定样本之间存在较大的重叠区域，这表明随着电网规模

的增大，电网特征的复杂性也相应增加，导致分类器更难以准确提取暂态稳定性特征。然而，经过数据增强后，图 3-7(b)中不同类型数据之间的距离相对增加，证明所提的数据增强方法提升了模型对复杂电气特征的提取能力，并表明其对于大规模电网的适用性。

3.6 本章小结

本章提出了一种基于生成对抗机制的临界失稳样本生成方法，旨在解决电力系统暂稳评估任务中的数据不平衡及 TSA 模型对临界失稳样本识别能力不足问题，以提高数据驱动暂稳评估模型的准确性。该方法将基于卷积机制的监督模型融入生成对抗结构，并通过改进生成器损失函数，最终构建能够生成大量临界失稳样本的生成算法。仿真结果表明，与现有方法相比，该算法能够生成更为真实且失稳时刻更长的失稳样本。通过在暂稳评估模型中验证，该方法生成的数据集显著提升了模型对失稳样本的识别能力。

第4章 基于生成对抗网络的数据重建方法

4.1 引言

随着物联网技术和智能传感器的快速发展,现代电力系统变得更具观测性^[48]。因此,越来越多的电力系统运行任务可基于数据驱动的方法解决,包括暂态稳定性评估^[71]和故障检测^[139]等。然而,由于数据采集单元故障、随机数据丢失和通信故障等原因^[100, 101],广域测量系统中的现场数据往往会出现数据缺失情况,严重降低数据驱动方法在电网应用中的可靠性^[71]。因此,为了保持现代电力网络的安全运行,亟需采取数据重建方法来消除不完整现场数据对数据驱动方法在线应用的不良影响。

如前文所述,在对电网缺失数据的重建工作中,广泛使用了基于 GAN 的数据重建方法。目前已有多种基于 GAN 的模型被用于学习数据分布^[131, 140–143]。具体而言,文献[140]提出了一种 GAN 搜索算法,用于自动搜索最优的 GAN 架构,以有效学习潜在的数据分布。文献[141]引入了一个语义引导的对比网络,以提高 GAN 方法在处理未知场景时的可迁移性。自注意力 GAN (Self Attention GAN, SAGAN)^[131]在图像生成任务中引入了注意力机制,对长距离依赖关系进行建模。而文献[142]对 Wasserstein GAN (WGAN)^[144]进行修改,以加快训练速度并提高性能。上述工作的目标是生成与真实样本相似的样本。

然而,上述工作在面向缺失电网数据恢复任务中存在以下局限性。首先,上述模型只关注数据的分布特性,而不关注生成样本和真实样本之间的数值差异。其次,这些研究普遍假设模型能够在完整的数据集上进行训练,即特征图中的每个测量值都是已知且可观测的。然而,由于设备故障和通信故障的普遍存在,很难获得完整的电力系统 PMU 历史测量记录作为重建模型的训练集^[49]。第三, TSA 任务的特征图表达了电力系统的时空信息,每个像素对应实际的电气测量值;而常规 GAN 网络仅评估重建特征图的整体真实程度,未充分挖掘特征图内部数据之间的时空依赖关系。最后,常见 GAN 网络^[107, 108, 142, 145, 146]的黑盒特性使电网运营商对重建数据的真实性产生质疑。

鉴于上述缺点,本章提出一种基于生成对抗机制的 PMU 缺失数据重建模型。与常规 GAN 结构相比,该模型提供了更具细粒度的训练反馈。具体而言,所提出的判别器评估生成样本中每个像素的真实性,而不仅是样本整体真实性。考虑到电网数据的时空依赖特性,该方法的架构利用了卷积网络、非局域模块

[133]和批归一化技术[118]等。具体而言,电力系统中的时空数据与图像的数据结构类似,因此采用 CNN 作为模型的主干结构,提取具有空间和时间依赖性的电气特征[147]。非局部模块提升了模型的多跳依赖建模能力,因此模型能够主动忽略故障 PMU 的时序信息。通过在 IEEE-39 和 NPCC 系统上进行仿真实验,表明所提方法在随机数据缺失和 PMU 故障情况下的重建性能优越。此外,本章还提供了一种在线 TSA 框架,证明所提模型在电网实际应用中的有效性。

除了 TSA 任务,数据驱动方法能够广泛应用于不同的电力系统分析任务,例如干扰识别[146]和电压稳定性评估[148],这些任务同样面临由于 PMU 在线测量不完整而导致的在线评估准确性下降的风险。因此,所提方法可以作为多种任务的预处理过程,在保留所提优化函数和模型结构的基础上,通过修改数据集参数使其适用于不同的数据重建任务。本章的主要贡献包括:

1) 提出基于 GAN 网络的缺失数据重建模型结构,以捕获系统电气特征图中的多跳依赖关系。所提判别器能够评估特征图中每个像素的真实性,从而有效地提取电力系统中的时空关系。

2) 在考虑生成和真实数据之间分布差异[149]的基础上,所提出算法将数值差异引入了损失函数,相比现有方法[150],本章方法更充分地利用了特征图中的真实已知信息,提升了模型的重建精度。

3) 所提算法不依赖于完整的训练数据,可以直接采用 PMU 历史测量数据作为训练数据库,提高了所提方法在实际系统中的适用性。

4) 通过注意力图的可视化,展示了模型在重建电力信息时的内部参数。这不仅证明了模型能够通过自适应忽略无效数据区域以获得较高的重建准确性,而且增强了该智能方法在实际应用中的可信度。

本章后续各小节的内容安排如下:第 2 小节阐述所提出的数据重建算法;第 3 小节从模型准确性和可解释性等方面分析所提模型,并与现有方法进行比较;第 4 小节提供一个在线 TSA 框架,其中所提出的缺失数据重建模型作为 TSA 分类算法的预处理过程;第 5 小节在 NPCC48 系统上验证了模型在噪声和在高 PMU 故障率场景下的鲁棒性;在第 6 小节对本章进行总结。

4.2 基于生成对抗机制的电网数据重建算法

本节提出了一种基于 GAN 结构的电力系统缺失数据重建模型。与基准模型[150]相比,所提出的方法改进了模型的结构和优化目标函数,使其更适用于电力系统高细粒度信息的重建。同时,在设计模型结构时,构建了能够自主识别并避开原始数据中缺失位置的算法结构。这样的设计不仅提高了模型的重建准确性,并且给模型带来了良好的可解释性,从而增强了算法的可信性。

4.2.1 电网数据重建算法基本框架

图 4-1 展示了采用标准 GAN 结构进行数据补齐的模型结构^[59]。模型包含两个深度神经网络，分别为生成器和判别器，用于学习电网数据中的时空分布。生成器期望生成与原始数据分布相似的数据样本，而判别器期望区分生成的数据和真实原始数据。




图 4-1 基于标准 GAN 结构的数据补齐算法

Fig. 4-1 Completion algorithm with a standard GAN architecture

如图 4-1 所示，这种方法需要完整的样本集作为判别器的真实标签样本，然而在历史 PMU 数据记录中，很难获得完整的样本集。因此，需要建立能够直接采用非完整样本集作为训练样本集合的数据重建算法。

为建立一个能够基于不完整集合训练的数据重建算法，本章构建了一个更具细粒度的数据重建算法，该算法基于生成对抗机制，整体架构如图 4-2 所示。

对比图 4-1 和图 4-2 可知，所提算法从生成器的输入输出、判别器的输入输出、损失函数以及模型网络结构等多个角度进行了改进，以建立一个重建颗粒度更高、不需要完整训练集且具备良好可解释性的数据补齐算法。

（1）考虑 PMU 数据缺失位置的生成器构建

与常见的 GAN 结构不同，本章构建的生成器 G 具有两个输入：噪声矩阵 $\mathbf{Z}$ 和掩码矩阵 $\mathbf{M}$ 。其中， $\mathbf{Z}$ 定义了输入噪声变量的先验分布^[109]。掩码矩阵 $\mathbf{M}$ 根据特征图中的数据缺失位置决定，掩码 $\mathbf{M} \in 0, 1^{d \times T}$ 指示 $\mathbf{X}$ 中哪些位置是已知的，其中 $m_i = 0$ 表示 x_i 在原始特征图中缺失，即该位置的电网量测值需要被补齐。

训练数据库的完整性因数据来源而异。如果数据来自历史 PMU 记录，则训练集为不完整数据集；而如果数据使用仿真生成，则为完整原始数据集。需

要注意的是，如果训练数据是包含所有量测值的完整矩阵，需要人为建立一个掩码矩阵，根据固定的缺失值比例随机抹去原特征图中的信息。生成器输出的矩阵 $\tilde{\mathbf{X}}$ 与原样本矩阵 $\mathbf{X}$ 维度相同。矩阵 $\tilde{\mathbf{X}}$ 将重建原始矩阵中包括已知位置和缺失位置的全部位置数据。




图 4-2 所提 GAN 模型的训练过程

Fig. 4-2 Training process of the proposed GAN model

生成器 G 的输入和输出如下式：

$$\tilde{\mathbf{X}} = G(\mathbf{Z}, \mathbf{M}) \quad (4-1)$$

(2) 面向掩码矩阵预测的判别器构建

判别器 D 以掩码矩阵和重建矩阵作为输入，重建矩阵是由生成数据和原始数据组合而成，如公式(4-2)所示，其中 $\odot$ 表示逐元素乘法。

判别器的输入为：

$$\mathbf{X} = \mathbf{M} \odot \mathbf{X} + (\mathbf{1} - \mathbf{M}) \odot \tilde{\mathbf{X}} \quad (4-2)$$

判别器的输出为：

$$\mathbf{M} = D(\mathbf{X}) \quad (4-3)$$

由以上公式可知，判别器的目标是区分观测（真实）数据和生成（伪造）数据，即正确预测掩码矩阵 $\mathbf{M}$ 。判别器可视为函数 D ，其函数输出 $D(\hat{\mathbf{X}})$ 的第 i 个分量代表 $\hat{\mathbf{X}}$ 中第 i 个分量被预测为原始真实信息的概率。

换言之，本章提出的判别器是对电网信息缺失矩阵 $\mathbf{M}$ 进行预测，即判断 $\hat{\mathbf{X}}$ 中的每一个元素是否为 PMU 中的已知数据。相比之下，在标准的 GAN 中（如图 4-1 所示），判别器的设计是预测生成器输出数据的整体真实程度。

4.2.2 生成对抗模型优化过程

GAN 结构的总体目标可视为关于分布差异的极小极大问题，表示为：

$$\min_G \max_D V(D, G) \quad (4-4)$$

价值函数 $V(D, G)$ 的表达式为：

$$V(D, G) = \mathbb{E}_{\mathbf{x}, \mathbf{m}} \left[\mathbf{M}^T \log D(\mathbf{X}, \mathbf{M}) + (\mathbf{1} - \mathbf{M})^T \log(1 - D(\mathbf{X}, \mathbf{M})) \right] \quad (4-5)$$

模型首先在固定生成器参数的情况下优化判别器，然后在固定判别器参数的情况下更新生成器，并依次重复这个过程。

（1）判别器的损失函数

判别器 D 的损失函数是一个二元交叉熵函数，表示为：

$$\mathcal{L}_D(\mathbf{m}_i, \mathbf{p}_i) = -\sum_i \left[m_i \log(p_i) + (1 - m_i) \log(1 - p_i) \right] \quad (4-6)$$

其中， m_i 是掩码标签， p_i 是掩码预测的概率，表示为：

$$p_i = D(\hat{x}_i, m_i) \quad (4-7)$$

（2）生成器的损失函数

生成器 G 的损失函数分为两部分，分别考虑生成数据和真实数据之间的分

布和数值差异。第一个损失函数 $\mathcal{L}_G$ 用于评估生成数据的分布，鼓励生成器产生与真实数据分布相似的数据，即促进生成数据的逼真性。第二个损失函数 $\mathcal{L}_M$ 用于评估重建数据与原始数据之间的数值差异。因此，生成器的训练目标是最小化这两个损失的加权和。生成器的总体损失函数如下：

$$\mathcal{L}_G(\mathbf{m}_i, \mathbf{p}_i) + \alpha \mathcal{L}_M(\mathbf{x}_i, \hat{\mathbf{x}}_i) \quad (4-8)$$

其中 α 是超参数（本章中设为 0.3）， α 的选择基于交叉验证。

考虑生成数据和真实数据之间分布差异的损失函数如下：

$$\mathcal{L}_G(\mathbf{m}_i, \mathbf{p}_i) = -\sum_i (1 - m_i) \log(p_i) \quad (4-9)$$

考虑生成数据和真实数据之间数值差异的损失函数如下：

$$\mathcal{L}_M(x_i, x'_i) = \sum_i (x'_i - x_i)^2 \quad (4-10)$$

其中 x'_i 和 x_i 是 $\hat{\mathbf{x}}$ 的预测值和真实值。

损失函数 $\mathcal{L}_M$ 在评估数据的数值差异时，最大程度上利用原始数据中的所有已知信息。具体如图 4-2 所示，本章所提算法适用于训练集完整或不完整两种情况。

相比之下，基准模型^[150]中的损失函数 $\mathcal{L}_M$ 表示为：

$$\mathcal{L}_M(x_i, x'_i) = \sum_i (x_i^{m'} - x_i^m)^2 \quad (4-11)$$

其中， $x_i^{m'}$ 和 x_i^m 分别是在 m_i 等于 1 的位置上的预测值和真实值。

如前文所述，当原始的训练数据集中所有数据都已知时，需要人为生成一个不完整矩阵，并将其输入生成器。然而，在这种情况下，公式(4-11)无法评估 $m_i=0$ 的位置上的数值差异，一定程度上降低了模型的重建能力，后续小结对此进行了验证分析。

综上所述，本章所提算法的训练过程如表 4-1 所示。

4.2.3 网络内部注意力可视化结构构建

本章算法在数据重建模型中引入了注意力机制。一方面，通过非局部模块生成的注意力图能够可视化模型权重，提供了一种解释模型行为的直观方法，并证明了该模型在电力系统中的适用性。另一方面，该机制通过忽略无效数据增强了模型的多跳依赖建模能力^[133]。考虑到真实电网存在 PMU 失效导致该

PMU 点位时序信息整体缺失的情况，这种数据缺失会比 PMU 中的数据随机丢失给数据重建带来更大的困难。因此，这种注意力机制实现了电力系统中任意两条母线之间时序特征的直接交互，增强算法捕捉长程依赖关系的能力。

表 4-1 数据补齐算法的训练过程

Table 4-1 Training procedure for the imputation algorithm

数据补齐算法的训练过程

输入：缺失数据矩阵 X ，缺失掩码 M ，学习率 η ，训练迭代次数 n

初始化：生成器网络 G ，判别器网络 D

For 每轮训练迭代

For $i=0,1,\dots,n$

从已知数据中采样小批量样本： X_{obs}, M_{obs}

从生成器网络中采样噪声： $Z \sim \text{Noise}$

生成缺失数据： $\hat{X}_{miss} = G(Z, M_{obs})$

合并已知和生成的数据： $X_{imp} = X_{obs} \odot (1 - M_{obs}) + \hat{X}_{miss} \odot M_{obs}$

计算判别器损失：

$L_D = -\mathbb{E}_{X_{obs}, M_{obs}} [\log D(X_{obs})] - \mathbb{E}_{Z, M_{obs}} [\log(1 - D(G(Z, M_{obs})))]$

更新判别器参数： $\theta_D \leftarrow \theta_D - \eta \cdot \nabla_{\theta_D} L_D$

对判别器参数进行截断： $\theta_D \leftarrow \text{clip}(\theta_D, -c, c)$

End For

For $j=0,1,\dots,n$

从噪声分布中采样大小为 m 的小批量噪声： $\{z_1, z_2, \dots, z_m\}$

计算生成器损失： $L_G = -\mathbb{E}_{Z, M_{obs}} [\log D(G(Z, M_{obs}))] + \alpha \cdot \text{数值损失}$

更新生成器参数： $\theta_g \leftarrow \theta_g - \eta \cdot \nabla_{\theta_g} L_G$

End For

End For

如图 4-3 所示，非局部操作可以定义为：

$$\mathbf{y}_i = \frac{1}{d} \sum_{j=1}^d f(\mathbf{x}_i, \mathbf{x}_j) g(\mathbf{x}_j) \quad (4-12)$$

其中， d 表示电力系统中记录信息的 PMU 个数，相应的特征图 $\mathbf{X} \in \mathbb{R}^{d \times T}$ 表示电力系统中 d 条母线上的 PMU 测量持续 T 个时刻。 $\mathbf{x}$ 和 $\mathbf{y}$ 的 i 和 j 是不同 PMU 的序号。 $g(\mathbf{x}_j) = \mathbf{W}_g \mathbf{x}_j$ 中 $\mathbf{W}_g$ 是权重矩阵， $\mathbf{y}$ 是输出的特征图。将特征图的两个位置作为输入并生成标量的函数 f 表达为：

$$f(\mathbf{x}_i, \mathbf{x}_j, H) = \theta(\mathbf{x}_i)^H \phi(\mathbf{x}_j) \quad (4-13)$$

其中， $\theta(\mathbf{x}_i) = \mathbf{W}_\theta \mathbf{x}_i$ 、 $\phi(\mathbf{x}_j) = \mathbf{W}_\phi \mathbf{x}_j$ 、 $\mathbf{W}_\theta \in \mathbb{R}^{C' \times C}$ 和 $\mathbf{W}_\phi \in \mathbb{R}^{C' \times C}$ 是可学习的权重矩阵， C 和 C' 为输入和输出的通道数。 H 是转置操作。

为了简化算法， θ 、 ϕ 和 g 被认为是线性变换操作，其可以被视为卷积核尺

寸为 1 的卷积运算^[133]。 $\theta(\mathbf{x}_i)$ 、 $\phi(\mathbf{x}_j)$ 和 $g(\mathbf{x}_j)$ 分别为 i 位置的查询矩阵, j 位置的键矩阵和值矩阵。对于给定的位置 i , 计算其查询值 $\theta(\mathbf{x}_i)$ 与每个位置键值的内积, 进而产生注意力分布。具体来说, 对 $f(\mathbf{x}_i, \mathbf{x}_j)$ 归一化后, 得到分配给 $g(\mathbf{x}_j)$ 的注意力分数。




图 4-3 用于 1 维特征图的非局部模块运算

Fig. 4-3 Non-local block module operation for one-dimensional feature maps

非局域模块的整体表达为:

$$\mathbf{z}_i = \mathbf{W}_z \mathbf{y}_i + \mathbf{x}_i \quad (4-14)$$

其中, $\mathbf{z}_i$ 为该模块的输出, $\mathbf{W}_z$ 将 $\mathbf{y}_i$ 的维度转化为与输入特征图一致。残差操作 $+\mathbf{x}_i$ 确保局部信息得到保留。

4.3 算例分析

本节通过数值实验讨论了所提模型的性能。第 4.3.1 节介绍了使用的数据; 第 4.3.2 节展示了模型的准确性, 并讨论了算法中每个模块的影响; 第 4.3.3 节通过可视化注意力图来展示 PMU 故障时的模型内部参数, 表明模型的准确性机制和可解释性; 第 4.3.4 节将所提方法与现有方法进行了比较。

4.3.1 数据集建立

本节基于 IEEE-39 系统中不同的运行点和事故点生成数据集。特征图 $\mathbf{X} \in \mathbb{R}^{d \times T}$ 表示 d 条母线上 T 个时刻的电压相角, 其中电压相角可以直接通过 PMU 采集^[151], 该特征图反映了电力系统的时空动态。在本章中, T 设置为 8,

d 设置为 20, 对应于从故障清除时刻开始, 在 20 条母线上记录 8 个时刻的电压相角^[71]。根据这种方式, 共生成 12000 个情景, 其中不稳定场景 4930 个。数据集以 8:2 的比例随机划分为训练集和测试集。暂态稳定性仿真采用 Power System Toolbox 3.0^[123]工具箱, 该软件具有高精度的电力系统仿真求解方法, 在相关文献中得到广泛应用^[124, 152-154]。

现有研究指出, PMU 在线量测的数据缺失, 会导致基于数据驱动的暂稳分类器的在线评估准确性下降^[49]。因此, 本章所提方法可作为 TSA 模型在线应用时的数据预处理模块, 以应对数据缺失导致的准确性下降问题。为保证所提方法在现有 TSA 模型上的适用性, 本章数据重建算法的样本空间 (包括运行范围和基准运行点) 与现有文献中 TSA 分类器模型的样本空间保持一致。为确保样本空间内的数据多样性, 本节考虑了多种运行点和故障情况。具体来说, 电力系统中的负荷在基准值的 80% 到 120% 范围内随机变动, 发电机出力逐渐从基准值的 120% 降至 80%^[49], 而母线电压保持在 0.95-1.05 p.u. 之间。此外, 系统可能在 4 条线路上发生三相接地短路故障, 故障位置随机设定为线路长度的 25%、50% 和 70% 处^[134], 以模拟不同的故障场景。

本章研究旨在恢复不完整特征图中的缺失数据。为进一步增强所提方法的实际适用性, 在考虑 PMU 数据随机丢失的基础上^[59, 107], 本节额外考虑了 PMU 故障失效的情况。此外, 为确保所模拟的 PMU 数据与真实场景特征一致 (包括采样率和缺失率), 将 PMU 的采样率设置为每周期两次^[151], 训练数据集中的数据随机缺失率和 PMU 故障率分别设置为 20% 和 10%^[100]。

4.3.2 算法结构和性能分析

针对模型性能评估, 通过 MAPE 和 MSPE 来衡量数据重建准确度, 具体计算方法如下:

$$\text{MAPE} = \frac{1}{n} \cdot \sum_{i=1}^n \left| \frac{\hat{x}_i - x_i}{x_i} \right| \quad (4-15)$$

$$\text{MSPE} = \frac{1}{n} \cdot \sum_{i=1}^n \left(\frac{\hat{x}_i - x_i}{x_i} \right)^2 \quad (4-16)$$

式中, n 表示数据集中样本的总数, $\hat{x}_i$ 和 x_i 分别表示第 i 个样本的重建值和真实值。

基准模型由两个全连接层构成^[150], 而所提方法对模型进行了改进。生成器和判别器的详细结构如表 4-2 和表 4-3 所示, 其中包括卷积神经模块、非局部模块、残差模块和批归一化层。

在设置算法超参数时，根据交叉验证，将算法学习率设置为 0.001。算法结构设计的基本思路是，通过相对简单的结构，构建参数较少且计算复杂性较低的算法。为增强 GAN 网络训练的稳定性，算法采用了细粒度更高的判别器，以此将电力系统的时空约束作为先验知识加速模型收敛。同时，为防止过拟合，本节使用了早停止技术，在 MAPE 开始增加时停止训练。

表 4-2 生成器模型
Table 4-2 Generator model

层	描述
卷积模块	[32 滤波器，卷积核尺寸 3，ReLU] × 2
非局部模块 1	$C'=32$
残差模块	[64 滤波器，卷积核尺寸 3，ReLU] × 2
非局部模块 2	$C'=64$
全连接层	Dropout 率 0.5
批归一化	Sigmoid

表 4-3 判别器模型
Table 4-3 Discriminator model

层	描述
卷积模块	[32 滤波器，卷积核尺寸 3，ReLU] × 2
非局部模块	$C'=32$
全连接层 1	Dropout 率 0.5
批归一化层	—
全连接层 2	softmax

表 4-4 不同模块组成下的模型性能对比(%)
Table 4-4 Comparison of model performance with different module compositions (%)

卷积模块	残差模块	非局部模块	批归一化	MAPE	MSPE
✓	—	—	—	3.05	0.38
✓	✓	—	—	2.85	0.30
✓	✓	✓	—	2.23	0.26
—	✓	✓	✓	2.18	0.16
✓	✓	—	✓	2.10	0.15
✓	✓	✓	✓	1.85	0.07

为研究模型组件对整体性能的贡献，在测试集中数据随机缺失率 20%的情况下，通过消融实验去除特定组件，分析不同模型结构下缺失数据重建的准确性。实验结果如表 4-4 所示。可以看出，各个组件均提高了模型性能。具体来说，卷积操作明显提升了模型提取电气数据的能力。卷积核的自适应性使其

能够准确平衡局部感受野内每个信息的贡献,促使模型有效捕获电气数据中的相关性。此外,非局部模块和批归一化的组合显著提高了重建准确性,非局部模块促使模型捕获全局特征^[133],而批归一化通过减少内部协变量偏移加快了深度神经网络的训练^[118]。

表 4-5 不同数据随机丢失率下的模型性能(%)

Table 4-5 Model performance under different random data loss rates (%)

模型	不同数据丢失率下的 MAPE			不同数据丢失率下的 MSPE		
	10	20	30	10	20	30
本节模型 (本节提出的损失函数)	1.74	1.85	1.99	0.02	0.07	0.09
本节模型 (基准损失函数)	1.98	2.03	2.20	0.06	0.13	0.21
基准模型 ^[150]	2.00	2.46	2.80	0.09	0.16	0.31

表 4-5 进一步比较了不同数据缺失率下所提方法与基准方法^[150]的性能。所提方法对基准模型进行了两个主要的改进。首先,设计了适用于处理时空电力数据的模型结构,如表 4-4 所示。其次,修改了损失函数以加强模型训练的数值约束,如公式(4-10)和公式(4-11)所示。表 4-5 中训练集采用完整数据集,特征图中的所有元素均为已知。在不同的数据缺失率下,所提模型的重建准确性明显优于基准模型。同时,随着缺失率的增加,基准模型的性能明显下降,表明简单的全连接网络对电力系统时空动态特性的捕捉能力有限,而所提模型具有更强的鲁棒性。此外,相对于基准损失函数公式(4-11),本节提出的损失函数(4-10)进一步提高了模型性能;原因是该损失函数在训练过程中利用了更多有效信息,显著增强了模型对缺失信息重建能力。

4.3.3 注意力图可视化

本节通过可视化所提算法内部参数的注意力权重,揭示了所提模型具有较高重建能力的原因。同时,所提算法能够自主识别并避开无效 PMU 位置,这为模型增加了良好的可解释性,从而增强了算法的可信性。在本章中,为模拟 PMU 故障失效的场景,故障 PMU 的时序测量数据全部设置为零。

注意力图 4-4(c)和(d)展示了两种 PMU 故障场景下的注意力分布,其相应的特征图如图 4-4(a)和(b)所示。当算法对缺失数据进行重建时,应忽略故障 PMU 序列,因为其无法为数据重建提供有用信息。从图 4-4(c)和(d)可以看出,所提算法可以自适应地忽略故障的 PMU 序列,专注于有效数据。根据公式(4-12),注意力分布通过特征图中每个元素的直接交互生成,因此所提出的模型具有全局感受野,从而自适应地识别并聚焦于特征图内的有效信息。




图 4-4 两种场景下的特征图和相应的模型内部注意力图

Fig. 4-4 Feature maps and corresponding internal model attention maps for both scenarios

4.3.4 与现有方法的对比

本节比较了所提模型与现有的缺失数据重建算法，包括 LSTM^[108]、GRU^[107]、Vanilla GAN^[59]、SAGAN^[131]、WGAN^[142]和带有梯度归一化的全注意力 WGAN（Full Attention WGAN with Gradient Normalization, FAWGAN-GN）^[143]。本节对比实验基于完整训练数据集进行，分别比较了随机数据缺失和 PMU 故障下的模型性能。

表 4-6 比较了不同数据缺失率下的模型性能。在 10% 的缺失率下，GRU 和 LSTM 重建准确性高于 Vanilla GAN，因为循环网络中的链式结构可以有效提取电力系统的时间相关性。然而，随着数据缺失率的增加，基于 GRU 和 LSTM 的方法性能显著下降；相反，基于 GAN 结构的模型能够保持高水平的重建准确性。在不同的数据缺失率下，所提模型均取得了最佳性能，其原因在于所提方法建立了细粒度更高的判别器，提升了模型对电气数据的学习能力。具体来说，本章特征图反映了电力系统时空关联性，特征图中每个像素代表某一时刻母线的电气测量值（如第 4.3.1 节所述）。因此，相比其他 GAN 结构，所提模型能够捕捉更具细粒度的信息，进而提升算法的重建准确性。此外，如

式(4-10)所示,模型优化过程中加入了数值差异约束,进一步增强了模型的数据重建能力。

表 4-6 不同数据随机缺失率下的模型性能(%)

Table 4-6 Model performance under different random data loss rates (%)

模型	不同数据丢失率下的 MAPE			不同数据丢失率下的 MAPE		
	10	20	30	10	20	30
LSTM ^[108]	1.80	2.53	3.21	0.05	0.17	0.58
GRU ^[107]	1.78	2.15	2.80	0.05	0.16	0.39
Vanilla GAN ^[59]	1.93	2.10	2.40	0.05	0.13	0.25
SAGAN ^[131]	1.81	1.98	2.29	0.03	0.12	0.20
WGAN ^[142]	1.90	2.05	2.35	0.03	0.14	0.21
FAWGAN-GN ^[143]	1.83	2.03	2.39	0.03	0.14	0.18
所提模型	1.74	1.85	1.99	0.02	0.07	0.09

表 4-7 不同 PMU 故障失效比例下的模型性能(%)

Table 4-7 Model performance under different PMU failure rates (%)

模型	不同 PMU 故障率下的 MAPE			不同 PMU 故障率下的 MSPE		
	10	15	20	10	15	20
LSTM ^[108]	2.59	3.09	3.68	0.19	0.45	0.61
GRU ^[107]	2.26	2.51	3.12	0.08	0.25	0.49
Vanilla GAN ^[59]	2.16	2.41	2.56	0.07	0.23	0.37
SAGAN ^[131]	2.01	2.15	2.41	0.06	0.17	0.33
WGAN ^[142]	2.18	2.42	2.61	0.08	0.20	0.39
FAWGAN-GN ^[143]	2.03	2.13	2.39	0.07	0.17	0.36
所提模型	1.88	2.00	2.21	0.04	0.15	0.26

表 4-7 展示了在不同 PMU 故障率下的模型性能,测试集的数据随机丢失率设定为 10%。与表 4-6 相比,模型的重建性能下降更为明显,表明重建整个时序的难度要远大于重建同比例下的随机缺失数据。此外,即使为 GRU 和 LSTM 提供了额外的前序时间数据(前序信息对这类数据预测方法是必须的^[107,108]),其模型性能依然低于 GAN 结构,并且由于链式算法结构的累积预测误差,GRU 和 LSTM 的重建误差随序列增加。此外,如表 4-7 所示,引入注意力机制的 GAN 模型,包括 SAGAN、FAWGAN-GN 和所提算法,通常表现出优于其他模型的性能。这表明注意力机制引入的全局感受野使模型能够专注于不完整样本中的有效信息。在模型对比中,所提模型由于模型结构和损失函数能够有效捕捉数据相关性,在大量数据缺失的情况下维持了更好的性能。通过图 4-4 中注意力图的可视化结果,可以看出所提模型能够自适应地忽略无效序列的干扰,专注于有效信息并重建数据。

综上所述，与循环网络结构^[107, 108]相比，所提模型避免了对前序数据的依赖。同时，所提模型通过非局部模块将注意力机制引入算法结构，重建准确性优于其他算法，并具备了一定的可解释性，增强了模型在实际应用中的可信度。

4.4 算法可拓展性测评：NPCC 48 机 140 节点系统算例

4.4.1 测试系统与数据生成

为进一步评估所提方法在大规模电力系统中对现场噪声和严重数据缺失情况的鲁棒性，本节在东北电力协调委员会（Northeast Power Coordinated Council, NPCC）的 48 机 140 节点系统上进行了实验。该系统的原型模型来自 Power System Toolbox，模拟了美国东北部和加拿大的电网^[155]，如图 4-5 所示。该系统包含 48 台发电机，140 个母线节点和 233 条线路。本节随机抽取 20 个发电机节点的信息构成特征图，遵循第 4.3.1 节中的规则生成数据样本。本节样本量 20000，以满足大规模电力系统的需求。




图 4-5 NPCC48 机 140 节点系统

Fig. 4-5 NPCC 48-bus 140-node system

为了测试数据重建方法对未经训练的更严重缺失比例场景的鲁棒性，本节将训练集中的 PMU 故障率设置为 30%，测试集中的 PMU 故障率增加到 50%，训练集和测试集中随机缺失数据的缺失比例均为 20%。此外，为了测试模型

对 PMU 现场噪声的鲁棒性，根据 IEEE 标准^[135]向测试集添加噪声，对于所有 PMU，测量误差不超过其实际值的 1%。本节采用文献[156]中的方法生成真实的噪声分布。

4.4.2 数值测试结果分析

如图 4-6 所示，即使在未经训练的场景中，即 PMU 故障率明显高于训练集的情况下，所提出的方法仍能自适应地忽略所有无效 PMU 的区域，证明了本章所提方法在数据重建中的鲁棒性。此外，由于测量噪声的存在，图 4-6(b)中的注意力图对有效信息的聚焦程度稍低于图 4-6(a)。然而，即使在存在测量噪声的情况下，所提方法仍能有效地过滤掉无效的 PMU 区域。该结果进一步验证了所提方法在实际测量中的鲁棒性和有效性。




图 4-6 NPCC 系统中无噪声和噪声场景下的注意力图

Fig. 4-6 Attention maps for noiseless and noisy scenarios in the NPCC system

表 4-8 不同 PMU 故障率下的模型性能(%)

Table 4-8 Model performance under different PMU failure rates (%)

	不同 PMU 故障率下的 MAPE			不同 PMU 故障率下的 MSPE		
	30	40	50	30	40	50
无噪声	1.98	2.23	2.56	0.12	0.32	0.46
包含 PMU 现场噪声	1.99	2.25	2.59	0.12	0.33	0.48

表 4-8 的结果显示，即使在更严重的 PMU 故障率下，所提出的方法仍能实现高精度的数据重建。同时，PMU 测量噪声对模型性能的影响并不明显。

这一结论与图 4-6 一致，即在有和没有 PMU 测量噪声的情况下，图 4-6(a)和图 4-6(b)生成了相似的注意力图。

综上所述，本节表明所提方法在面向更大电网时，依然具有较高的重建准确性，并对噪声和更严重数据缺失场景具有较高的鲁棒性，表明其在电力系统中的实际应用潜力。

4.5 本章数据重建算法对在线 TSA 准确率的提升验证

为证明所提数据重建方法在暂稳评估中的必要性和有效性，本节设计了一个在线 TSA 的框架，验证其对 IEEE-39 系统 TSA 准确性的提升，如图 4-7 所示。




图 4-7 包含前置数据重建模型的在线 TSA 框架

Fig. 4-7 Online TSA framework with the front-end data reconstruction model

在该框架中，首先将 PMU 收集到的不完整现场数据送入所提生成器，生成器输出的信息与 PMU 中的已知数据结合，构成在线重构信息，随后将其送入 TSA 分类器，最终输出 TSA 分类结果。

由于 GAN 结构中判别器的作用是在训练过程中提高生成器性能，该框架中仅使用了生成器结构。需要强调的是，本节以单个 CNN 分类器作为 TSA 分类模型的示例^[49]，CNN 分类器可替换为其他 TSA 分类器结构。本章的 TSA 模型基于数据无缺失的离线仿真样本建立，而 TSA 的在线输入数据中存在缺失情况，以更准确地展示所提数据重建方法对 TSA 在线评估准确性的提升。在线应用时，生成器和分类器的内部参数保持固定，同时由于生成器的输出和输入数据维度一致，前置数据重建结构无需对 TSA 分类器的结构进行任何修改。

在测试集中数据缺失率为 30%的情况下，采用所提算法对原数据进行重建，数据重建准确率达到 97.12%。在此基础上，经过在线 TSA 分类，分类准确率从 90.2%提高到了 98.2%。图 4-8 通过 t-SNE 技术^[157]对分类器最后一层全连接层特征进行可视化。如图 4-8(a)所示，原数据中不同标签的样本之间存在大量重叠，表明分类器无法有效区分稳定和不稳定样本。然而，在图 4-8(b)中，经过缺失数据重建后，不同标签数据之间的距离有所增加。这表明采用本章提出的数据重建模型能够有效提升电力系统中的 TSA 准确率。




图 4-8 不同数据集下提取特征的可视化

Fig. 4-8 Visualization of the feature extraction for different datasets

此外，只需要相应地修改后续的分类模型，本节提出的框架即可迁移到其他数据驱动的电力系统任务，例如干扰识别^[146]。

4.6 本章小结

本章提出了一种基于 GAN 结构的模型，用于智能电网缺失数据的重建。通过消融实验验证了所提模型结构和损失函数的有效性，并与现有方法进行了比较。实验结果显示，在随机数据缺失和 PMU 故障条件下，所提模型具有更高的数据重建准确度。此外，算法注意力分布证明模型能够自适应地关注有效数据，进一步增强所提方法在实际应用中的可信度。此外，本章还提出一个用于 TSA 任务的在线框架，证明所提数据重建方法在 TSA 任务中的有效性和必要性。该数据重建方法可以通过调整输入特征的参数以满足不同任务需求，应用于其他的电力系统数据驱动任务中。例如，该方法可基于潮流信息训练，作为电压稳定性评估任务的前置数据重建模型。

第 5 章 基于注意力机制的暂态稳定评估模型

5.1 引言

基于人工智能的电力系统暂态稳定评估可视为分类任务，将系统的运行状态分为稳定和失稳两类。通过机器学习算法，建立系统运行点与暂态稳定性预测分类之间的映射关系，预测当前电气样本的暂态稳定性。

如前文所述，已有大量基于深度学习的暂稳预测方法。其中，由于电气量测信息的时间相关性，深度学习中主要采用 CNN^[15, 158]和 LSTM^[83]提取电网动态时序关系。文献[83]基于 1D-CNN 提取暂态时序特征，文献[158]采用特殊结构的 RNN 网络平衡评估精度和响应时间。以上方法均具有较高的泛化能力和准确率。然而，在捕捉特征间的序列依赖关系时，CNN 的“感受野”层叠结构加剧了运算复杂度，而 RNN 串行输入会带来高运算成本和梯度问题。此外，以上深层网络可解释性较差，引发电网调度人员对预测结果的不信任。

为解决上述算法的问题，文献[46]首次提出以注意力运算为核心的 Transformer 模型，给序列特征处理提供了全新的深层网络架构。Transformer 模型的核心为多头自注意力机制。注意力机制给高价值信息分配高权重，本质上是对信息处理资源的高效分配^[46]。其自适应注意力权重分布体现了输出数据与输入序列特征间的相关性。相比 1.4.3 节中所提到的可解释性方法，Transformer 的可解释性来自算法结构中的注意力运算，在模型迭代降低损失的过程中生成较为稳定的特征注意力分布，展示特征对于决策的贡献度，并给后续的数据收集方向提供建议。

同时，相比采用故障清除时刻的量测信息进行单次预测^[66, 84]，多阶段预测能够有效降低失稳漏判率。在多阶段预测暂稳状态时，文献[159, 160]在故障清除时刻后采用滑动窗逐次预测暂稳状态；文献[161]将故障前 10 个周波数据作为原始输入特征量的稳态运行部分，在故障持续阶段多次进行暂稳评估，并在故障清除时刻确定最终的暂稳评估结果。因此，本章方法采用的特征空间包含故障发生前、故障发生时刻和故障清除后的 3 个时刻断面信息；通过注意力机制提取特征空间内序列前后状态之间的关系，本章实验证明采用多时刻信息作为特征空间能够提高模型准确率，有利于模型对电力系统动态响应的表达。

本章提出一种基于 Transformer 编码器的多阶段暂态稳定评估方法，模型采用发电机电气信息对系统暂稳状态进行多阶段评估以减少失稳漏判，因机组失稳特性随着时间逐渐明显，使其更易被模型识别。此外，相比其他深层算法，

Transformer 模型的全局感受野实现了特征间的直接交互，其注意力分布体现了特征的价值度，通过注意力机制对关键特征的自适应聚焦，给深层模型带来了良好的可解释性。在 IEEE-39 和 Polish-2383 节点系统上的仿真结果表明，本章所提方法在模型准确度、可解释性、以及面对污染数据时的鲁棒性 3 个方面相比常规数据驱动模型具有更优越的性能。

本章所提的基于 Transformer 编码器的多阶段暂态稳定评估方法主要有如下特点：

1) 为建立面向暂稳评估问题的分类模型，通过修改标准 Transformer 的编码器—解码器结构，构建多层编码器与 softmax 分类层组成的 Transformer 分类器，输出暂稳评估结果。

2) 为提高暂稳评估的准确性，降低失稳漏判，提出多阶段暂态稳定评估方法。采用稳态状态、故障发生时刻和故障清除后的当前时刻信息构建特征空间。通过将稳态和故障发生时刻信息加入特征子集，给模型自注意力运算提供了更丰富的上下文信息，实现时序信息的直接交互，提升模型性能。

3) 本章重点分析 Transformer 模型中的注意力机制，通过解构不同输入特征和故障场景下的注意力分布，展示模型内部参数对失稳关键特征的注意力聚焦过程，给数据驱动方法下的暂态稳定评估带来了一定可解释性。

4) 考虑到真实电力系统场景中存在数据污染，通过展示注意力分布对高价值特征的聚焦，表明算法有效抑制了异常信息对暂稳预测的干扰。通过展现本章所提方法在数据污染下的鲁棒性，证明所提方法适用于实际电力系统。

5.2 面向电气时序信息提取的 Transformer 注意力网络

本章以 Transformer 编码器作为电气信息提取层，Transformer 编码器由 N 个相同的子模块 (Transformer block) 堆叠组成，如图 5-1 所示，子模块包含多头自注意力层 (Multi-head Self-attention, MSA) 和前馈神经网络层 (Feed-Forward Network, FFN) 2 个主要部分，引入残差连接 (Residual Connection) 和层归一化 (Layer Normalization, LN) 以防止梯度退化并加速算法收敛。

5.2.1 面向电气时序的位置编码

位置编码用来描述特征间的相对位置关系，与嵌入特征层叠加。Transformer 模型中的位置编码计算公式如下：

$$\begin{cases} P_E(p_{os}, 2i) = \sin\left(\frac{p_{os}}{10000^{2i/d_{model}}}\right) \\ P_E(p_{os}, 2i+1) = \cos\left(\frac{p_{os}}{10000^{2i/d_{model}}}\right) \end{cases} \quad (5-1)$$

式中： p_{os} 代表序列长度； i 代表特征向量的维度下标； d_{model} 为特征长度。因为正弦和余弦函数具有周期性， $P_E(p_{os}+k,n)$ 可以表示为 $P_E(p_{os},n)$ 的线性变化，从而识别特征间的相对位置关系。




图 5-1 Transformer 编码器子模块的基本架构

Fig. 5-1 Basic architecture of Transformer encoder submodules

在分析电力系统动态变化中的时序数据时，位置编码用于标记特征在时间维度上的先后顺序。

5.2.2 面向电气特征的多头自注意力提取层

自注意力运算模块为 Transformer 编码器的核心单元。如图 5-1 中所示，通过并行 h 次注意力计算，得到多个参数独立的“表示子空间”，扩展了模型专注于不同特征的能力。

输入矩阵 W 经过 3 种不同的线性变换得到查询矩阵 Q ，键矩阵 K 和值矩阵 V ，计算公式如下：

$$\begin{cases} Q = W^Q X \\ K = W^K X \\ V = W^V X \end{cases} \quad (5-2)$$

式中: $W^Q, W^K, W^V \in R^{d_{model} \times d_k}$; $\{W^Q, W^K, W^V\}$ 将嵌入向量 X 从 d_{model} 维度映射到 d_k 维空间。

多头自注意力计算公式如下:

$$\begin{cases} \text{Attention}(Q, K, V) = \text{Softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \\ \text{head}_i = \text{Attention}(Q_i, K_i, V_i) \\ \text{MultiHead}(Q, K, V) = \text{Concat}(\text{head}_1, \text{head}_2, \dots, \text{head}_i)W^O \end{cases} \quad (5-3)$$

式中, 点乘注意力为特征融合运算, softmax 函数有利于反向传播梯度计算, 同时将结果平滑至 0-1 区间。采用 $\sqrt{d_k}$ 尺度化以避免点积过大造成 softmax 梯度过低。多组 d_k 维空间内的注意力分布采用 Concat 拼接, 经过权重矩阵 W^O 变换得到最终的注意力层输出。

不同特征间的注意力权重值为 $\text{Softmax}(Q_i K_j^T / \sqrt{d_k})$, 在提取机组注意力分布时, 将机组的量测信息整合作为该机组的特征, 并由此得到注意力分布图。相比卷积和循环网络, 自注意力运算通过点乘融合实现不同位置特征之间的交互, 不受特征间距离的限制, 从而增强了特征的代表能力。因此, 自注意力机制具备全局感受野, 能够在数据受污染的情况下保留更多信息^[133]。相比之下, 卷积和循环结构则是在空间或时间上处理局部域, 需要通过重复卷积和逐步传播信号的方式捕获特征间的远程依赖关系, 进而增加算法面向污染数据时的优化难度^[162]。此外, 也有研究指出自注意力机制对于污染数据的鲁棒性来自于其能够动态调整感受野以适应不同信息的注意力偏好^[162]。因此, 所提算法通过将自注意力机制引入 TSA 模型中, 使其在面向受污染的电气信息时仍能维持较好的鲁棒性。

图 5-2 展示了多头注意力模块内特征维度的变化。经过完整的多头注意力运算后, 特征被映射回原始空间, 输出特征维度与嵌入特征相同。这实际上保持了电气信息的特征粒度, 也就是数据的精细程度。

5.2.3 前馈神经网络

前馈神经网络层由 2 层全连接网络构成, 每层对输入向量进行线性映射, 中间的隐藏层使用 ReLU 函数激活。前馈神经网络公式如下:

$$F_{\text{FN}}(x) = \max(0, xW_1 + b_1)W_2 + b_2$$

(5-4)

式中： x 为注意力层归一化后的输出向量； W 为权重向量； b 为偏置项。




图 5-2 Transformer 注意力层矩阵维度变换

Fig. 5-2 Transformation of dimensions in the Transformer attention layer

5.2.4 层归一化运算与残差连接

如图 5-1 所示，特征矩阵经过多头注意力层和前馈神经层后均会采用层归一化与残差连接。

层归一化运算中每层神经元共享均值和方差，使层输入归一化为标准正态分布，增强反向传播信息的流动性。其公式如下：

$$\begin{cases} \mu = \frac{1}{T} \sum_{i=1}^T X_i^2 \\ \sigma = \sqrt{\frac{1}{T} \sum_{i=1}^T (X_i - \mu)^2} \\ L_N(x) = \alpha \frac{x - \mu}{\sqrt{\sigma^2 + \varepsilon}} + \beta \end{cases}$$

(5-5)

式中， T 为该层神经元的个数， μ 为均值， σ 为标准差， x_i 表示特征向量的第 i 维， α 、 β 为可学习的模型参数，通过反向传递更新， ε 为防止除数为 0 设置的小数。

残差连接结构使梯度传递更为高效，避免模型退化。经残差连接的 Transformer Block 内部数据如下式：

$$\begin{cases} X' = L_N(M_{\text{MultiHead}}(X)) + X \\ X_{\text{output}} = L_N(F_{\text{FN}}(X')) + X' \end{cases} \quad (5-6)$$

式中： X_{output} 和 X 分别为Transformer Block的输出和输入矩阵； X' 为前馈网络层的输入矩阵； L_N 为层归一化运算。

5.3 多阶段暂态稳定评估框架

5.3.1 面向暂态稳定评估问题的分类模型架构

为构建面向暂态稳定评估问题的Transformer分类模型，需要修改标准Transformer的编码器—解码器^[46]结构。电力系统评估可被划分为分类问题，因此建立多层编码器与softmax(·)函数分类层组成的Transformer分类器。

Transformer被广泛应用于自然语言处理领域，其嵌入特征(Embedding)层采用skip-gram索引将单词映射为稠密连续的向量，通过查表方式统一原始词信息的特征维度，这与本章工作有2个主要区别：

1) 词向量是单通道(channel)向量，而电力系统具备功角、电压、有功、无功等特征，为多通道向量；多通道向量无法在保留特征序列信息的情况下直接通过Transformer进行注意力融合。

2) 经过skip-gram的单词会自动获得统一的词向量维度，而电力系统中不同节点(如发电机节点和母线节点)可能具有不同的特征维度。

对此，在Embedding层采用 1×1 卷积对原始高维电气信息进行数据融合，这种操作解决了上述问题。面向电气特征提取，这种 1×1 卷积方法设计具有以下优点：

1) 对原始高维电气量直接进行注意力运算会破坏特征图中的序列信息，且模型无法聚焦于某一类具体的电气特征。而使用 1×1 的卷积核可以将4通道数据(功角、电压、有功、无功)降维为单通道数据。这不仅减少Transformer中注意力交互的计算量，更是保留了数据序列信息，且使模型能够通过注意力运算识别重要电气特征(如故障场景下的重要机组)，进而实现算法的可解释性。

2) 因为本章采用发电机节点信息构建特征集，算法天然具备统一的数据维度。在面向其他工作时，如需要处理不同维度的数据，则在 1×1 卷积的基础上进行局部卷积^[163]操作统一数据的特征维度，进而实现注意力运算。

本章构建的基于Transformer编码器的暂态评估判别模型如图5-3所示。该模型可以直接面向底层数据实现电气信息的分层表达，提取有价值的高阶特征，建立量测数据与稳定类别之间的映射关系。模型内部通过注意力运算，自

适应聚焦于高价值电气特征。

同时，本章在深层网络隐藏层内部加入概率为 50%的 Dropout，以削弱神经元间的共适应关系，降低模型对特定特征的依赖，避免模型过拟合。




图 5-3 基于 Transformer 的 TSA 模型

Fig. 5-3 Transformer-based TSA model

5.3.2 多阶段电力系统暂稳评估流程

本章以电力系统量测数据为原始信息，提出以 Transformer 分类模型为核心的多阶段暂态稳定评估流程，包括离线训练和在线评估 2 个部分，如图 5-4 所示。

1) 时域仿真阶段

获取电力系统运行历史稳态数据和故障信息，对电网不同运行方式进行时域仿真。稳定判据采用暂态稳定指数（Transient Stability Index，TSI）：

$$TSI = \frac{360^\circ - |\Delta\delta_{\max}|}{360^\circ + |\Delta\delta_{\max}|} \tag{5-7}$$

式中： $\Delta\delta_{\max}$ 为仿真时长内任意 2 台发电机相对功角差的最大值。当 $TSI>0$ 时，样本判定为稳定，反之，判定为失稳。

2) 样本生成阶段

电力系统暂态稳定性刻画了大扰动下电力系统的动态行为，相比采用单时刻电气信息，多断面电气量给自注意力点乘运算提供了更丰富的上下文信息，因此本章采用系统多时刻断面信息构成特征集。

为使样本集具备时空上的完备性，采用故障前稳态时刻 t_0 、故障发生时刻 t_f 和故障清除后当前时刻 t_{c+n} 的信息构建特征空间（见表 5-1）， t_0 时刻信息采用故障发生前一周期的数据，样本采样频率 50Hz。




图 5-4 基于 Transformer 机制的多阶段暂态稳定评估流程

Fig. 5-4 Multi-stage transient stability assessment process based on Transformer mechanism

表 5-1 模型特征集

Table 5-1 Model feature sets

模型采用特征
t_0 、 t_f 、 t_{c+n} 时刻, 发电机母线电压
t_0 、 t_f 、 t_{c+n} 时刻, 发电机有功、无功输出和功角

对输入矩阵采用 z-score 标准化处理, 以消除属性量纲的差异影响, 数学公式为:

$$l' = \frac{l - \bar{L}}{\sigma_L} \quad (5-8)$$

式中, l' 表示标准化后的 l , $\bar{L}$ 表示 l 的均值, σ_L 表示 l 的标准差。

3) 模型优化阶段

模型训练过程中通过降低整体的损失函数值来提高模型预测精度。本章采用交叉熵损失函数作为代价函数, 因算法的复杂度较高, 对损失函数进行 L2 正则化, 通过 L2 范数约束权重, 防止模型对高维电气数据的过拟合:

$$\text{CrossEntropy}(y, \hat{y}) = -\sum_{i=1}^N y_i \log(\hat{y}_i) + \lambda \|\theta\|_2^2 \quad (5-9)$$

其中, y 是真实标签, $\hat{y}$ 是模型预测的概率向量, N 是类别数量, y_i 和 $\hat{y}_i$ 分别表示真实标签和模型预测的第 i 类的概率, λ 是 L2 范数的正则化参数, θ 是模型的参数。

此外, 为减少模型训练时间, 本章采用 Adam 优化器自适应调节学习率, 在损失函数梯度的相反方向上更新模型参数。

4) 在线应用阶段

模型在故障清除时刻首次评估系统暂稳状态, 并以 0.2s 为间隔持续监测, 以减少因故障清除初期暂态失稳特性不明显而导致的失稳漏判。在故障清除时刻 (t_c), PMU 实时读取 t_c 量测数据, 将稳态运行 t_0 、故障发生时刻 t_f 、故障清除时刻 t_c 的电气信息送入评估模型输出第一次暂稳判断。 P_0 为分类层 softmax 函数输出的失稳概率^[49], 当 $P_0 > 0.5$, 输出失稳标签 0, 反之, 输出标签 1。为减少稳定场景的误判, 引入失稳阈值 $\tau (\tau \geq 0.5)$, 若 $P_0 > \tau$ 判定为暂态失稳, 由电网控制中心处理, 如不满足, 则继续读取 (t_{c+1}) 时刻的信息, 将 t_0 、 t_f 、 t_{c+1} 时刻的电气信息送入评估模型继续评估, “第 n 次持续判定为稳定且最后 1s 内量测的发电机最大功角差均小于 5° ”^[164]后评估结束, 此时系统恢复稳态。 n 根据实际电网需求和离线训练样本分布设定。本章中 n 设定为 750, 即故障清除后 15s 内持续判稳且最后 1s 内发电机最大功角差小于 5° 后模型退出运行。

5.4 算例分析

5.4.1 数据集生成

算例采用基频为 50Hz 的 IEEE-39 节点电力系统。在 80%–120% 的负荷水平内随机生成原始负荷样本，相应改变发电机出力使系统功率平衡且母线电压维持在 0.95pu–1.05pu 的合理范围。故障均发生于输电线路，故障地点位于距离线路首端的 2%、50%、98% 处^[160]。故障类型为三相短路，假设故障清除后网络拓扑结构不变，故障发生时刻为 0.02s，故障持续时间分别考虑 0.10s、0.15s、0.20s，仿真时长 20s。仿真软件采用 MATLAB Power System Toolbox (PST) 3.0^[123]，共仿真 18400 个场景，其中稳定场景 11580 个，失稳场景 6820 个。根据 8:1:1 的比例随机划分训练集、验证集和测试集。

5.4.2 模型性能的评估指标

电力系统暂态稳定评估属于非平衡分类问题。仅采用评估准确率 A_c 作为评估模型的评价指标，会给模型评价带来误导。

为全面评估所提方法的性能，本章引入混淆矩阵，针对电气数据集中稳定样本多于失稳样本的特点相应修改精确度和召回率指标，各类指标定义如表 5-2 所示。

表 5-2 暂态稳定评估混淆矩阵

Table 5-2 Confusion matrix for transient stability assessment

		真实结果	
		稳定	失稳
预测结果	稳定	TP	FP
	失稳	FN	TN

$$\text{recall} = \frac{T_N}{T_N + F_P} \quad (5-10)$$

$$\text{precision} = \frac{T_N}{T_N + F_N} \quad (5-11)$$

$$A_c = \frac{T_P + T_N}{T_P + T_N + F_P + F_N} \quad (5-12)$$

$$F_1 = \frac{2 \cdot \text{precision} \cdot \text{recall}}{\text{precision} + \text{recall}} \quad (5-13)$$

召回率 recall 和精确率 precision 分别代表被正确预测的失稳样本占真实失

稳样本和预测失稳样本的比例。 A_c 反映评估模型的全局正确率。 F_1 是 recall 和 precision 的调和平均数,能更为客观地反映模型对失稳样本的预测能力。因此本章主要采取准确率 A_c 和 F_1 值评价模型性能。

5.4.3 与现有方法的对比

目前,时序特征抽取网络主要存在 RNN、CNN 和 Transformer 这 3 类。图 5-5 展示了不同网络中的时序提取结构,RNN 中的循环神经元通过记忆前序信息影响后序节点的输出;CNN 通过卷积核逐层提取局部信息以最终获取全局信息;Transformer 在位置编码层标记特征的相对位置,通过自注意力机制实现全局特征的快速交互。




图 5-5 不同时序网络结构

Fig. 5-5 Different temporal network architectures

本节选取 LSTM 和 CNN 作为深层对比模型,LSTM 是特殊结构的 RNN,具有与传统 RNN 相同的序列串行输入,但能有效缓解梯度弥散问题。同时采用暂稳分析领域常见模型 SVM 和 DT 作为对比算法。

本节所有算法的 Batch size 为 400,深层模型均设置 epoch 最大为 200,初始学习率 0.0025,L2 的惩罚因子 0.001,dropout 率 0.5,采用网格搜寻最优超参数。SVM 采用径向基函数, $C=10$, $\gamma=0.12$;DT 采用 C4.5 算法,置信因子为 0.2;Transformer 中 h 为 3,Transformer 子模块数为 2;LSTM 基于文献[165]中的结构,隐层数目 5,隐层单元的数目分别为 500,600,700,600,500;CNN 模型基于文献[158]中的 4 层卷积结构,卷积核 3×3 ,每层卷积层后连接 2×2 的最大池化层,以及 2 个全连接层。每层卷积核分别为 32,32,64,64,激活函数 ReLU。SVM 和 DT 不具备记录特征时序的能力,其特征需要相应调整为 1-D 维度。本节对比模型评估性能均采用多阶段预测后得出。模型训练与测试均采用 Python 语言、基于 PyTorch 框架实现,服务器为 6240R 2.4G,24C/48T,数据存储为 npz 格式。

以下章节检验各个对比算法的样本分类性能,所有模型在 $p_0 > 0.5$,即

label=0（失稳标签）时，将该场景判定为失稳，并进一步讨论失稳阈值 τ 对于多阶段模型漏判和误判率的影响， τ 在降低误判的同时，可能导致模型对失稳样本识别时刻的延时，增加漏判风险，因此 τ 需要根据模型权衡取值， τ 取值不会影响模型训练过程。对于各个模型均进行 5 次重复实验，准确率取测试平均值。

由于失稳样本中的失稳特性会随着时间更加明显，使其更容易被模型正确识别，实验中可发现，测试集所有失稳场景中系统最快在故障清除后 0.54s 失稳，为给信号传输和紧急控制保留一定时间裕度，因此其失稳场景下的准确率定义为失稳样本是否能在失稳发生时刻（即 $TSI=0$ 的时刻）前 0.5s^[50] 被模型正确识别。

对测试集中 1840 个场景（其中失稳场景 892 个）进行预测，漏判个数取 5 次重复试验的平均值。表 5-3 验证了多阶段模型能够有效降低失稳场景漏判，在第一次预判时，模型平均漏判样本 12.2 个，98.6% 的失稳样本被识别。因机组的失稳特性会随时间愈发明显，远离模型分类边界，截止到失稳发生（即 $TSI=0$ 的时刻）前 0.5s，漏判个数为 1.2 个，此时模型准确率 99.53%， F_1 值 99.48%。

表 5-3 Transformer 模型多阶段性能

Table 5-3 Multi-stage performance of the Transformer model

评估时刻	漏判个数
t_c	12.2
t_{c+1}	7.8
t_{c+2}	7.6
t_{c+3}	7.0
t_{c+4}	5.2

图 5-6 展示了不同时序提取算法的模型训练效率，Transformer 模型的 F_1 值在第 9 轮训练中最先达到 90%，其训练效率高于 CNN 和 LSTM 结构的时序提取算法，证明其全局特征的快速融合有效加速了模型性能提升。

表 5-4 展示了多种算法下多阶段预测最终的准确率和 F_1 值，Transformer 的 F_1 值分别比 CNN 和 LSTM 高出 0.48% 和 0.24%。3 种深层模型在采用多阶段预测后，其准确率均高于 99%，相比常见的单阶段模型^[66, 84, 158]，在准确率上有一定提升。同时，对比现有文献中常见的“特征提取+浅层算法”，从上述数据可以看出，Transformer 模型性能明显优于前置 PCA 的 SVM 和 DT，表明本节模型相比 SVM 和 DT，在处理高维数据时具有更优的复杂函数表征能力。深层模型的耗时对比见表 5-5。




图 5-6 不同深层网络的训练过程
Fig. 5-6 Training processes of different deep networks

表 5-4 不同模型下的模型性能比较(%)
Table 5-4 Performance comparison of different models (%)

评估模型	评估准确率 A_c	F_1
Transformer	99.53	99.48
CNN	99.28	99.00
LSTM	99.34	99.24
PCA+SVM	96.68	95.81
PCA+DT	95.91	95.09

表 5-5 深层模型耗时比较(s)
Table 5-5 Consumption time comparison of deep models (s)

评估模型	训练 50 epoches 耗时	在线评估耗时
Transformer	1197.65	0.015
CNN	702.02	0.011
LSTM	798.24	0.019

5.4.4 模型对电气特征的注意力分布可视化

注意力机制因其良好的特征权重分布可视化，被逐渐应用于模型的可解释性分析。注意力的可解释性体现为：注意力权重的高低对应特征的重要程度，高权重的特征单元对输出结果具有更高决定性^[46]。

在自然语言处理和计算机视觉领域，注意力机制实现了模型对关键词语^[46]和关键像素^[166]的关注，本节用以探讨注意力机制是否适用于电力系统这种复杂物理模型，进而分析电气特征与暂稳输出之间的映射关系。注意力分布图像中颜色越深代表该特征分配到的注意力权重越高，本节分别分析模型在面向时

间特征和机组特征时的注意力分布,证明 Transformer 的注意力机制在面向电网物理特征时能够实现对高维电气时空特征的辨识。

(1) 面向时间维度时的注意力分布

图 5-7 为 100 个场景中模型对时间断面的注意力分布。随着训练次数增多,模型注意力概率明显向 T_{c+n} 时刻,即故障清除后的特征偏移。图 5-7(d)呈现出与图 5-7(c)相似的注意力分布,说明模型准确率在第 20 轮训练后已经达到了较高值,模型梯度更新缓慢,其注意力分布趋于稳定,统计第 100 轮训练时不同时刻特征的注意力分布,得出 t_0 、 t_f 、 t_{c+n} 时刻的注意力分布分别占 5.29%、24.03%和 70.68%。




图 5-7 训练过程中不同时段特征的注意力分布

Fig. 5-7 Attention distributions of temporal features during training process

上述结果表明,在时间维度上,故障清除后的数据对暂稳评估价值度最高,模型赋予更多的注意力权重,而稳态状态时的信息价值度最低。

为验证电气特征间注意力分布的有效性,并说明采用 t_0 、 t_f 、 t_{c+n} 信息相比

单一时刻数据作为特征子集能够提升模型性能，表 5-6 对比了模型在故障清除时刻的评估准确率，为此分别采用 t_c 时刻， t_f 、 t_c 时刻和 t_0 、 t_f 、 t_c 时刻特征构建特征集并训练模型。

表 5-6 采用不同时间断面特征后模型性能比较(%)

Table 5-6 Comparison of model performance using different temporal section features (%)

时间断面	t_c	t_f 、 t_c	t_0 、 t_f 、 t_c
F_1	95.99	96.84	98.71

(2) 面向发电机组时的注意力分布

如果采用发电机电气信息作为模型 Embedding 层，模型中不再采用 Position Embedding 显式标注特征时序。如图 5-8、5-9 所示，模型对不同故障下的机组呈现了不同的注意力权重分布，证明模型在面对不同故障时能够自适应地更加关注于某些发电机的量测信息，而这些发电机的状态变化会更大程度上影响系统的暂稳状态。

图 5-8 展示了包含全部故障场景的注意力分布。因不同故障下的机组状态不同，机组注意力会呈现出相对均衡的分布。从原始注意力分布中提取故障发生于线路 6-5 和 20-34 中的注意力分布，结果如图 5-9 所示。




图 5-8 面向全部场景的发电机注意力分布

Fig. 5-8 Distributions of generator attention across all scenarios

由图 5-9(a)可以看出，在不同负荷场景下，当故障发生于输电线 6-5 时，模型的注意力分布显著集中于 G39，在 100 组数据中的注意力平均值为 79.02%，明显高于其他机组。这表明 G39 在暂态稳定和失稳的不同场景下，其运行状态会有区别于其他机组。为验证上述结论，在 MATLAB 中进行故障时域仿真可知，在该故障下，如果发生暂态失稳，与其他机组失去同调性的机组为 G39，如图 5-9(a)所示。

同理，图 5-9(b)中模型注意力自适应聚焦于 G34 和 G39，注意力分布分别

为 49.87%和 33.11%。从 MATLAB 仿真结果可知，当故障发生于输电线 20-34，G34 机组为主要失同调机组；而 G39 机组在仿真中为平衡机组，通过调节有功和无功出力维持仿真系统的稳定，因此其特征变动相对较大，模型也会给其分配较高的注意力权重。统计同一故障场景下的注意力分布后发现，除平衡机组外，每个机组的注意力权重均聚焦于该故障下的失稳机组，且同类故障场景具备相似的机组注意力分布。




图 5-9 面向特定故障下的发电机注意力分布
Fig. 5-9 Distributions of generator attention for specific faults

从本节可以得出，Transformer 算法实现了深层网络对关键特征的自适应加权，识别出高价值的电气特征，并证明高注意力权重的特征会更大程度上影响模型决策，面向暂稳分析问题，Transformer 模型较其他常见深层网络具有有效的可解释性。

5.4.5 模型面对异常特征的鲁棒性

因实际应用场景中可能存在数据污染，为验证注意力运算对异常特征的抑制能力，将样本集内的部分数据遮挡并替换为随机值。新加入的随机特征向量服从高斯分布，均值为 0，方差为 1。

为展示 Transformer 模型内部对异常信息的处理，将 t_{c+n} 时刻的特征随机遮挡 30%，注意力可视化结果如图 5-10 所示。




图 5-10 在特征遮挡下不同时段特征的注意力分布

Fig. 5-10 Attention distributions of temporal features under feature occlusion

大量遮挡最具价值的故障清除时刻后的特征会导致模型训练减缓。在第 2 轮训练中，不同特征之间的注意力差异并不明显。与之相对，在图 5-7(a)中，模型已经明显呈现出对不同特征的注意力倾斜。

然而随着迭代次数增加，模型最终依然聚焦于故障清除后时刻。在图 5-10(d)的第 100 轮训练中，注意力在 t_0 、 t_f 、 t_{c+n} 时刻的分布值为 9.21%、19.34% 和 71.45%，与图 5-7(d)呈现出相近的注意力分布。这表明 t_{c+n} 时刻未被污染的数据依然会为模型判别提供最具价值的信息，模型关注于故障清除时刻。

对比不同模型对异常数据的处理能力，如表 5-7 所示，异常数据导致所有模型的性能有了不同程度的下降。其中，Transformer 表现出最强的鲁棒性，在异常数据占比 10% 时准确率和 F_1 分别下降 0.23% 和 0.46%，当异常数据占比 30% 时，依然能维持 95% 以上的准确率和 F_1 高于其他模型。Transformer 特征间以点乘方式进行自注意力运算，其全局感受野使其具备了相比常见算法更强的上下文信息整合能力^[133, 162]，使模型在面对污染数据时维持较高的准确率。

表 5-7 含异常特征时模型的性能比较(%)

Table 5-7 Performance comparison of models with abnormal features (%)

模型	不同异常特征比例时的模型 A_c			不同异常特征比例时的模型 F_1		
	10	20	30	10	20	30
Transformer	99.30	98.32	96.09	99.02	97.92	95.17
CNN	98.93	97.25	93.81	98.28	96.70	92.89
LSTM	98.89	93.49	89.70	98.29	92.93	88.96
PCA+SVM	95.59	93.03	91.95	94.74	92.17	90.67
PCA+DT	94.88	92.86	89.97	94.20	92.33	88.94

在含有大量异常数据的场景下, CNN 模型较 LSTM 表现出了更好的性能, 因其池化层中的信息降维削弱了无效信息对模型的干扰。LSTM 模型对特征污染表现出很高的敏感度, 随着异常数据的增多评估性能急速下降, 在异常数据 30% 时, LSTM 的准确率和 F_1 值下降到 90% 以下, 低于 PCA+SVM 网络, 这表明 LSTM 性能依赖于输入信息的完整度, 不适用于可能存在大量数据污染的应用场景。

5.4.6 模型失稳阈值分析

本节采用 softmax^[49] 函数作为分类层函数, 分类层对每一组样本输出失稳概率 P_0 和稳定概率 P_1 , 二者相加为 100%。当 $P_1 > 0.5$ 时, $P_1 > P_0$, 模型 label=1。 P 可以视为标签的可信程度。

为降低模型的稳定样本误判率, 模型输出失稳判定的条件由上文中“ $P_0 > 0.5$ ”即“label=0”, 进一步限制为“ $P_0 > \tau(\tau \geq 0.5)$ ”。

如图 5-11 所示, 试验结果表明, 失稳阈值 τ 的加入会降低误判率。为使模型准确率更具参考性, 本节加入了“失稳样本需要在失稳发生时刻前 0.5s 识别, 否则判定为漏判”这一限制, 由于较高的稳定失稳阈值会造成失稳识别时刻的延后, 因此 τ 的加入会在降低误判率的同时, 使模型漏判率有一定升高, 当 τ 大于 0.8, 漏判率升高明显。因此将 τ 设定为 0.80, 测试集结果如下: 在 τ 由 0.5 升为 0.8 时, 漏判率由 0.13% 升为 0.16%, 误判率由 0.84% 降为 0.42%, 模型最终准确率 99.70%, F_1 为 99.69%。




图 5-11 不同失稳阈值下的模型性能

Fig. 5-11 Model performances under different instability thresholds

5.4.7 与现有多阶段暂稳方法的对比分析

本章采用多阶段的暂态评估方法，在故障清除时刻首次输出暂稳评估。因失稳特性随着时间推移愈发明显，模型漏判率降低。在表 5-8 展示现有的多阶段算法与所提算法的对比，3 种算法均能够达到较高的准确率，然而相比现有文献，本章加入“在失稳发生时刻前 0.5s 识别出失稳”这一限制，如果模型在失稳时刻前 0.5s 内没有识别出失稳，则被判定为漏判，给紧急控制保留一定时间，因此本章的漏判率更具实际参考性。表 5-8 中 Transformer 评估方法的准确率、漏判率和误判率累计结果，是基于满足“第 750 次持续判定为稳定且最后 1s 内量测的发电机最大功角差均小于 5°”或“在故障发生前的 0.5s”得出，如前文所讨论的，这给失稳控制留出了足够的时间。

表 5-8 所提模型与现有文献中多阶段模型对比

Table 5-8 Comparison between the proposed model and the multi-stage models in the existing literature

算法	特征选择	样本量	准确率(%)	漏判率(%)	误判率(%)
DBN ^[159]	原始特征、人工经验特征、SDAE 提取特征	37400	99.32	没有写明	没有写明
CNN ^[160]	功角、电压幅值、功角轨迹簇、电压幅值轨迹簇	37400	99.68（累计到第 10 次检测）	0.12（累计到第 6 次检测）	0.32（累计到第 6 次检测）
Transformer	功角、电压幅值、有功、无功	18400	99.70	0.16	0.42

本章方法具有以下特点：1) 特征维度较低，不需要人工特征筛选，采用稳态、故障发生和清除时刻信息构建的特征空间给算法提供了丰富的前后文信息。2) 相比 CNN 和 DBN，Transformer 不仅能够提取时序关系，还能够快速提取全局信息，表现出良好的分类性能。3) 自注意力结构带来了良好的可解释性，一方面给出特征权重，为数据收集提供方向；另一方面，将深层网络透明化，增加了神经网络在实际应用中的可信性。

5.5 算法可拓展性测评：以 Polish-2383 节点系统为例

5.5.1 测试系统与数据生成

本节将所提出的方法应用于一个规模更大、系统更复杂的实际电力系统，即 Polish-2383 节点系统。该系统母线数为 2383、线路数为 2896，发电机数和负荷数分别为 327 和 1561。系统基本潮流数据由该系统 1999-2000 年冬季高峰期整理而成^[138]。采用与 IEEE-39 节点系统一致的数据生成规则，该算例生成 30000 个场景，其中稳定场景 22843 个，失稳场景 7157 个。

5.5.2 数值测试结果分析

本节将所提算法与 CNN、LSTM、SVM、DT 算法进行对比，以验证所提算法对于复杂电力系统的适用性。为降低模型的复杂度，将图 5-1 中嵌入特征向量层改为卷积核大小 3×1 且步幅 (strides) 3×1 的卷积层。失稳阈值 τ 设为 0.5。

从表 5-9 和表 5-4 中的结果可以看出，在 Polish-2383 节点系统下，各个深层模型依然能够维持较高的准确率。Transformer 模型在两种规模电网的测试中均表现出色，准确率分别为 98.25% 和 99.53%， F_1 值也保持在 98% 以上。这表明 Transformer 模型对于电网规模的扩展性和鲁棒性较强，能够有效地捕捉大规模电网中的复杂关系。

表 5-9 Polish-2383 系统下的模型性能比较(%)

Table 5-9 Model performance comparison under the Polish-2383 system (%)

评估模型	评估准确率 A_c	F_1
Transformer	98.25	98.12
CNN	97.52	97.09
LSTM	95.00	94.50
PCA+SVM	88.00	87.29
PCA+DT	87.91	87.33

相比之下，CNN 和 LSTM 在大电网中的表现略有下降，准确率分别为

97.52%和95.00%。此外，值得关注的是，在 Polish-2383 节点电网中，基于传统机器学习方法的 SVM 和 DT 模型在暂态稳定评估上出现了明显的下降，准确率甚至低于 90%。这可能表明，这两个模型在处理大电网数据时受到了特征图高维度和数据复杂性的影响，限制了其性能表现。这也突显了深度学习模型在处理大规模电网数据时的优势。

表 5-10 的结果显示，与表 5-9 相比，各个评估模型的准确率和 F_1 值都有所下降。Transformer 模型的准确率从 98.25%下降到了 97.65%，CNN 和 LSTM 模型也呈现下降趋势。这表明，即使采用了深度学习方法，模型在存在异常数据的情况下仍然受到了一定的影响。

表 5-10 Polish-2383 系统下异常数据占比 10%时的模型性能(%)

Table 5-10 Model performance on the Polish-2383 system with 10% abnormal data (%)

评估模型	评估准确率 A_c	F_1
Transformer	97.65	96.94
CNN	96.28	96.09
LSTM	93.78	93.00
PCA+SVM	87.48	86.43
PCA+DT	86.91	86.17

PCA+SVM 和 PCA+DT 的性能大幅下降表明其对异常数据的敏感性。这可能是由于浅层网络结构相对简单，在处理高维度信息时，难以提取其中的有效信息，导致性能急剧下降。这表明相对于传统的浅层网络结构，深度学习模型在处理复杂的大电网数据时具有更好的适用性。

5.6 本章小结

本章提出了一个基于 Transformer 自注意力编码器的暂稳多阶段预测模型，面向底层量测数据预测系统暂稳状态，其点乘自注意力机制实现了全局特征间的快速交互，并充分利用电力系统时序信息，其性能高于常见算法和单次预测模型。同时，该方法展现出良好的可解释性，通过展现深层网络内部工作过程，证明模型在训练迭代中能够自适应关注并聚焦于重要特征，所提算法呈现的内部参数分布符合实际系统的物理关系，提高了算法决策的可信度，并给未来的数据收集提供了方向。同时，所提方法具有良好的鲁棒性，注意力机制有助于评估模型在污染数据下维持较高性能，从而表明模型在真实电力系统中的适用性。

第6章 基于注意力机制的在线暂态稳定监测模型

6.1 引言

由第5章研究可知, Transformer 编码器在学习和提取电力系统暂态稳定知识方面表现出良好的性能。该结构通过全局注意力快速提取时序电力测量信息,从而提高了暂态稳定性预测的准确性和面对噪声的鲁棒性。因此, Transformer 自注意力网络可作为一种性能优越的暂稳信息提取结构。

为构建更适用于实际电力系统的 TSA 模型,本章基于 Vision-Transformer (ViT) 构建持续在线暂稳评估模型,并在失稳预警后提供失稳机组预测。同时,所提方法能够在继电保护失效的情况下依然生效。本章方法相对于第五章有以下改进:

1) 所提方法提升了算法适用性,主要表现在两个方面。

首先,本章提出了一种基于当前测量数据的 TSA 监测系统,其无需获知故障清除或故障发生的精确时刻,以避免保护信号和 PMU 之间的时钟误差对 TSA 的影响。TSA 模型需要准确的清除时刻信息作为输入数据,故障清除和发生时刻由继保信号和故障指示器提供^[167],这要求 PMU 和电子设备之间时钟同步。然而,网络时间协议^[168]中的故障和普遍存在的通信延迟增加了电子设备和 PMU 之间时间同步的难度,即使轻微的信号延迟也会导致 TSA 模型性能明显下降^[134]。因此,本章提出了基于当前时刻的在线 TSA 监测方法,模型不需要获知故障清除和发生时刻,从而提升暂稳评估模型的准确性。

此外,本章的方法同样适用于继电器故障的情况,使其更符合实际现场要求。由于 PMU 不记录故障清除时刻,暂稳评估模型通常由继保动作信号触发^[50,169],在继保失效的情况下将无法正常工作。正如文献^[168,170]所指出的,随着电网中新能源占比提高,继电器故障或拒绝动作的风险显著增加,引发严重级联故障或停电^[170]。因此所提方法基于当前运行点提供暂稳预测,包括故障发生前到清除后的阶段,以及即使在故障未清除的继保拒动场景,仍能为系统运营商提供系统失稳预警。

2) 本章提出了一种识别发电机失稳的算法,为进一步应急控制提供了建议。正如文献^[81]中所指出的,仅通过电力系统未来的暂态状态难以制定有效的失稳对策。在采取控制措施之前,需要知道每个发电机的运行状态,即稳定或不稳定。

因此,本章在电力系统暂稳预测的基础上,提供每个发电机的稳定性预测。

这有助于电力系统操作人员快速采取控制措施，减少系统暂态失稳带来的不利后果。

3) 与第 5 章采用的标准 Transformer 相比，ViT 将电力系统中的不同变量（如功率输出、电压幅值）分配给不同的通道，因此更适用于电气样本的多维特性。此外，与第 5 章的标准 Transformer 不同，基于 ViT 的算法可以通过添加通道扩展输入维度，将其他类型的电气变量加入特征图。

总之，本章构建了一个两阶段的在线监测系统。第一阶段预测电力系统的暂态稳定性，第二阶段在失稳情况下识别失稳发电机^[81, 171, 172]。本章所提方法的创新点主要包括以下三点：

1) 建立基于 ViT 注意力机制的 TSA 和失稳发电机识别模型，通过引入的注意力计算提高了模型对噪声的鲁棒性。特别是在多标签失稳发电机识别任务中，与现有方法相比，所提算法显著提高了模型性能。

2) 提出了基于当前运行状态的 TSA 持续监测系统，其不依赖于准确的故障发生和清除时刻，因此不受 PMU 和电子设备之间时钟不同步的影响。此外，通过学习故障未正确清除的电气样本轨迹，该方法适用于继电器故障场景，能够在继保失效时为系统运营商提供系统失稳的早期警告，提升该方法的实用性。

3) 提出了一种自适应调整的失稳阈值判定方法，在误判和漏判之间做出适当权衡。

6.2 基于 ViT 的 TSA 分类模型和失稳机组识别模型

6.2.1 ViT 模型电气信息提取层

ViT 对标准 Transformer 网络进行改进，使其适应多通道特征图。与标准 Transformer 接受一维序列输入不同，ViT 将多通道特征转化为扁平化的二维补丁（patch）序列。

本章模型使用时空矩阵 $x \in \mathbb{R}^{H \times W \times C}$ 作为样本特征图，其中， H 和 W 分别表示电气特征的高度和宽度，即系统中的发电机数量和记录的周期数， C 表示电气变量的数量。这种数据特征更适合采用 ViT，而不是标准 Transformer 提取样本信息。

图 6-1 展示了所提出的 ViT 暂稳分类器结构，由三个主要模块组成，包含位置嵌入（position embedding）的线性变换嵌入层、Transformer 编码器和分类器层。




图 6-1 ViT 结构: (a)模型主要结构; (b)Transformer 编码器结构; (c)多头注意力层; (d)注意力机制

Fig. 6-1 ViT architecture: (a) main architecture of the model; (b) Transformer encoder architecture; (c) multi-head attention layer; (d) attention mechanism

电力系统中的时间序列信息被均匀划分为非重叠的补丁序列，其序列长度为：

$$n = HT / p^2 \tag{6-1}$$

其中， p 是每个补丁的分辨率， H 和 T 分别表示样本的高度和宽度。通常，较小的补丁尺寸会导致较长的序列长度，反之亦然。

每个补丁被线性投影映射到一个 token 嵌入层，和一个可学习分类 token，即 CLS (Classification Token)，进行拼接。CLS 是 ViT 中的一个独特结构，用以总结所有补丁的全局特征表示。此外为了保持原始特征空间中的空间排列，每个补丁都添加了位置嵌入信息。

所有的 token，包括 CLS，都被送入 Transformer 编码器，该编码器由 l 个相同的 Transformer 模块堆叠而成。每个 Transformer 模块包含一个 MSA 层和一个 FFN 层。为了简化优化过程，MSA 和 FFN 层都使用了 LN 和残差连接。Transformer 子模块的处理步骤可以表示为：

$$\begin{aligned} z'_\ell &= MSA(LN(z_{\ell-1})) + z_{\ell-1}, \ell = 1 \dots L \\ z_\ell &= FFN(LN(z'_\ell)) + z'_\ell, \ell = 1 \dots L \end{aligned} \tag{6-2}$$

其中, z'_ℓ 和 z_ℓ 分别表示 MSA 模块和 FFN 模块的输出特征。

6.2.2 ViT 模型分类输出层

本章需要建立两个独立的模型。第一个模型输出暂态稳定分类, 第二个模型在第一个模型判定失稳时启动, 输出该状态下的失稳机组预测。因此, TSA 模型是二分类模型, 失稳机组识别模型则是多标签模型。这两个模型采用相似的 ViT 结构建立特征提取层, 但输出层的损失函数有所不同。

(1) 暂态稳定分类模型输出层

暂态稳定分类层采用 softmax 函数, 如下所示:

$$P(y^{(i)} = j | \mathbf{X}^{(i)}) = \frac{e^{\theta_j^T \mathbf{x}^{(i)}}}{\sum_{l=1}^k e^{\theta_l^T \mathbf{x}^{(i)}}} \quad (6-3)$$

其中, $y^{(i)}$ 是输入 $\mathbf{x}^{(i)}$ 的标签, θ_j 是类别 j 的参数向量, $P(y^{(i)} = j | \mathbf{X}^{(i)})$ 是输入 $\mathbf{X}^{(i)}$ 被识别为类别 j 的概率, k 是类别的数量。因此, $\mathbf{X}^{(i)}$ 被分配到具有最高概率的类别, 即

$$\tilde{y}^{(i)} = \underset{j}{\operatorname{argmax}} P(Y = j | \mathbf{X}^{(i)}) \quad (6-4)$$

式中, $\tilde{y}^{(i)}$ 为第 i 个数据的类别。

本章中 softmax 分类器的训练通过下式实现:

$$J_s(\theta) = - \left[\sum_{i=1}^m \sum_{j=1}^K 1\{y^{(i)} = j\} \log \frac{e^{\theta_j^T \mathbf{x}^{(i)}}}{\sum_{l=1}^K e^{\theta_l^T \mathbf{x}^{(i)}}} \right] + \lambda_s \sum_{i=1}^K \|\theta_i\|^2 \quad (6-5)$$

式中, $y^{(i)}$ 为样本 $\mathbf{X}^{(i)}$ 的正确故障类别, 在函数(6-5)中加入了权值衰减项 $\lambda_s \sum_{i=1}^K \|\theta_i\|^2$ 对较大的权值进行惩罚, 并通过参数 $\lambda_s \in \mathbf{R}^+$ 调节。

函数(6-5)中的指示函数 $1\{y^{(i)} = j\}$ 如下所示:

$$1\{y^{(i)} = j\} = \begin{cases} 1, & y^{(i)} = j \\ 0, & y^{(i)} \neq j \end{cases} \quad (6-6)$$

(2) 失稳机组识别模型输出层

失稳机组识别的分类输出层采用 sigmoid 函数, 由于失稳状态下可能出现

多个失稳机组，该模型可以视为多标签模型。

在整个多标签分类任务中，每个类别都有一个独立的 sigmoid 输出。因此，如果有 C 个类别，最终的输出将是一个长度 C 的概率向量，每个元素都在 $(0,1)$ 范围内，表示样本属于对应类别的概率。在本章中， C 为电网中机组的个数，失稳机组识别模型的输出表示为：

$$\text{Output} = [\text{sigmoid}(z_1), \text{sigmoid}(z_2), \dots, \text{sigmoid}(z_c)] \quad (6-7)$$

其中， z 是模型的特征提取层输出，经过 sigmoid 函数将其转换为概率值，表示每个机组处于稳定状态的概率。

在多标签分类任务中，sigmoid 分类器的训练通过优化以下损失函数实现：

$$\text{Loss} = -\frac{1}{N} \sum_{i=1}^N \sum_{j=1}^M y_{ij} \log(\hat{y}_{ij}) \quad (6-8)$$

其中， N 是样本数量， M 是标签数量， y_{ij} 表示第 i 个样本的第 j 个标签的真实标签， $\hat{y}_{ij}$ 是第 i 个样本的第 j 个标签的预测概率。

6.3 在线暂稳评估方法

研究的框架由离线训练和在线识别两个过程组成。如图 6-2 所示，在离线训练阶段，利用带有相关标签的样本集合，分别对 TSA 和失稳发电机的识别模型进行训练。而在在线识别阶段，使用所提方法进行暂态稳定评估和失稳发电机的预测。

6.3.1 离线训练过程

(1) 时域监测阶段

电力系统的运行数据和故障信息可通过时域仿真模拟或历史记录获取。在进行时域仿真时，故障清除后，稳定标签由 TSI 指标决定。

$$TSI = \frac{360^\circ - |\Delta \delta_{\max}|}{360^\circ + |\Delta \delta_{\max}|} \quad (6-9)$$

式中， $|\Delta \delta_{\max}|$ 表示任意两台发电机之间在没有任何控制干预下的最大转角差绝对值。当 $TSI > 0$ 时，系统被视为稳定，反之，则被视为不稳定。

模型的样本标签 y 表示为：

$$y = \begin{cases} 1 & \text{if } (t_E < t_F) \text{ or } (t_F \leq t_E < t_C \text{ and } TSI_F \geq 0) \text{ or } (t_E \geq t_C \text{ and } TSI_C \geq 0) \\ 0 & \text{if } (t_F \leq t_E < t_C \text{ and } TSI_F < 0) \text{ or } (t_E \geq t_C \text{ and } TSI_C < 0) \end{cases} \quad (6-10)$$

其中, t_E 表示观测窗口的结束时刻 (即当前的监测时刻), t_F 表示故障发生时刻, t_C 表示故障清除时刻。在式(6-10)中, 标签表示在当前时刻的运行点下, 不进行任何控制干预的暂稳预测。 TSl_F 表示继保失效情况下的暂稳预测, 而 TSl_C 表示继保作用下故障被清除后的暂稳预测。




图 6-2 离线训练阶段

Fig. 6-2 Offline training phase

图 6-3 展示了现有文献中代表性的标签设定方式。文献[15, 147]在故障被清除后, 基于公式(6-3)输出暂态不稳定概率 $P_{i=T}(y=0|X)$, 以此进行暂稳评估。文献[147]中的 TSA 模型需要在收到继保动作信号后激活, 受到电气设备之间时钟同步误差的影响, 且不适用于继保失效情况。与本章研究类似, 文献[15]的方法也不需要准确的故障发生和清除时刻, 但同样不适用于继保失效情况, 无法在继保拒动时做出暂态失稳预警。

然而, 如图 6-3(c)所示, 本研究中的在线监测系统不依赖于准确的故障发生和清除时刻, 仅基于当前测量数据进行暂稳预测。该方法同样适用于继电器失效场景, 因为模型建立了当前时刻信息与无干预下的系统稳定性之间的映射, 不受系统故障或故障清除的影响。

此外, 本章构建了一个多标签分类器, 用于识别不同系统运行点下的失稳

发电机。失稳发电机是指与平衡机组的转子角度差大于 360° ^[81]的机组。不稳定发电机的标签设为 1，稳定发电机的标签设为 0。

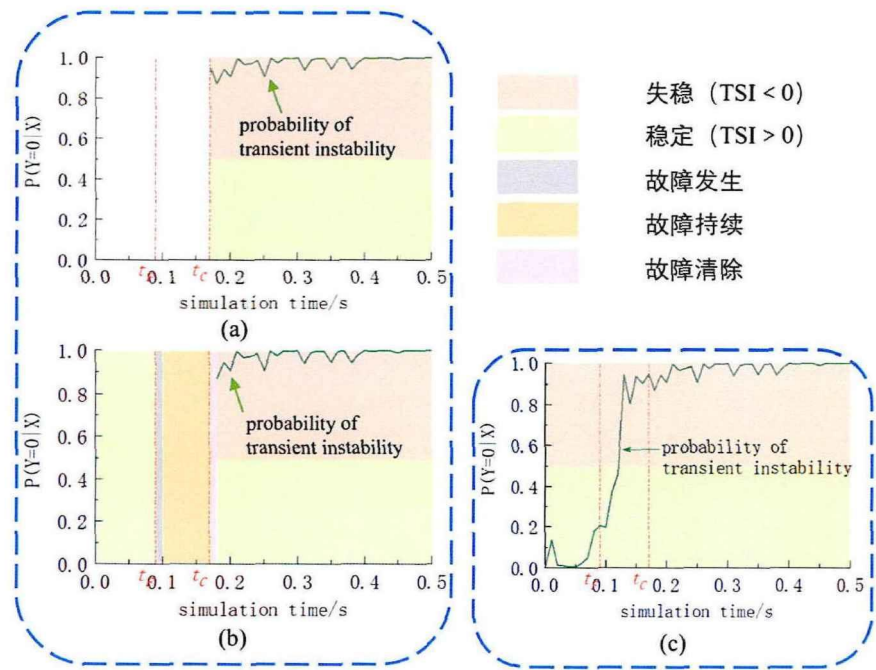


图 6-3 (a)现有方法[147], (b)现有方法[15]和(c)本研究中的模型输出值和标签
Fig. 6-3 Output values and labels of (a) existing method [147], (b) existing method [15], and (c) the proposed method

(2) 数据集构建阶段

在本章中，故障持续时间分别设定为 0.10 秒、0.15 秒和 0.20 秒。图 6-4 展示了本章数据集与文献[15, 147]的对比。文献[147]的数据集仅包含故障清除后的数据，因此只能在继电器动作后评估暂态稳定性。而文献[15]的数据集允许所提出的方法持续识别系统运行状态，但未加入继保失效后的运行数据，不适用于继电器失效场景。




图 6-4 (a)现有算法[147], (b)现有算法[15]和(c)所提算法的数据集
Fig. 6-4 Datasets of (a) existing algorithm [147], (b) existing algorithm [15] and (c) the proposed algorithm

本研究将故障前、故障期间、故障清除以及继保失效时的电气轨迹都加入数据库，由此所提方法将建立电网全时段信息与该运行点下系统稳定性之间的映射，模型映射逻辑清晰，从而构建一个更具适用性的暂稳监测系统。

样本特征包括每个发电机的电压相角、有功和无功功率。应用 z-score 归一化消除特征之间尺度差异的影响，得到

$$Z = \frac{X - \mu}{\sigma} \quad (6-11)$$

其中 X 和 Z 分别是原始值和归一化值， μ 和 σ 分别是均值和标准差。

(3) 模型优化阶段

在暂态稳定性评估任务中，使用交叉熵损失函数，并结合正则化方法^[173]防止过拟合。此外，采用 Adam 优化器加速模型训练过程，自适应调节梯度下降过程中的步长^[174]，以帮助算法在梯度变化较小时保持速度，并加速模型收敛。

Adam 的优化更新规则如下：

$$\begin{aligned} m_t &= \beta_1 \cdot m_{t-1} + (1 - \beta_1) \cdot \nabla J(\theta_t) \\ v_t &= \beta_2 \cdot v_{t-1} + (1 - \beta_2) \cdot (\nabla J(\theta_t))^2 \\ \hat{m}_t &= \frac{m_t}{1 - \beta_1^t} \\ \hat{v}_t &= \frac{v_t}{1 - \beta_2^t} \\ \theta_{t+1} &= \theta_t - \frac{\eta}{\sqrt{\hat{v}_t} + \epsilon} \cdot \hat{m}_t \end{aligned} \quad (6-12)$$

其中， t 是当前迭代次数， θ_t 是参数， $\nabla J(\theta_t)$ 是损失函数关于参数的梯度， m_t 和 v_t 分别是一阶矩估计（动量）和二阶矩估计， β_1 和 β_2 是衰减系数，通常取为接近 1 的值，如 0.9 和 0.999； $\hat{m}_t$ 和 $\hat{v}_t$ 是偏差校正后的矩估计， η 是学习率， ϵ 是为了数值稳定性而添加的小常数。

6.3.2 在线识别阶段

本章中，模型通过滑动窗口持续输出暂稳预测。滑动观测窗口由当前时刻和前序 ($T-1$) 个时刻的测量值组成，采样频率为 1 个周期。

来自 PMU 的测量数据以多维数组的形式存储在神经网络中。图 6-5 通过红绿蓝 (RGB) 通道展示了一个典型的失稳场景，该场景记录了从系统稳态到故障清除后的系统变量。其中，发电机最大转角差超过 360° 的失稳时刻为

第 3.96s。可以观察到，在故障发生时刻 t_F 和故障清除时刻 t_C ，系统变量发生了明显变化。失稳发电机组表现出与其他发电机组不同的特征，并且随着时间的推移，其失稳特征变得更加明显。由此证明，基于当前量测信息进行暂稳预测和失稳机组预测具有可行性。




图 6-5 失稳场景中的电力系统动态信息可视化

Fig. 6-5 Visualization of power system dynamic information in an instability scenario

如图 6-6 所示，在线识别阶段模型基于当前运行点持续提供暂稳预测，在其预测满足失稳阈值后，模型正式被判定为暂态失稳。将模型首次满足失稳阈值的时刻设定为 t_{alarm} ，该时刻电气数据将被送入下一个模型，用于输出失稳发电机组的预测。




图 6-6 在线监测阶段

Fig. 6-6 Online monitoring stage

模型正式输出失稳结论的判定标准为：

$$P_{t=\tau}(y=0|X) > \tau \quad (6-13)$$

其中, $P_{t=\tau}(y=0|X)$ 为当前时刻模型 softmax 分类层输出的失稳概率, τ 为设定的失稳阈值。

显然, 公式(6-3)中的分类概率可视为该预测的可信程度^[137]。如果一个类别的概率输出远高于其他类别, 则预测更有说服力。例如, 在二分类器中, $P_{t=T}(y=1|X)=0.99$ 和 $P_{t=T}(y=0|X)=0.01$ 表示标签 1 的概率很高。

阈值 τ 的设计需要考虑两个因素。首先, 考虑分类器对不平衡数据的预测偏差, 由于稳定样本的数量远多于不稳定样本, 可以通过调整 τ 来校正模型的分类不平衡。其次, 假阳性 (FP) 样本 (即被预测为稳定的不稳定样本) 通常比假阴性 (FN) 样本 (即被预测为不稳定的稳定样本) 造成更严重的不良影响。然而, 仅关注减少 FP 样本会增加系统的运行成本。

因此, 本章提出一个阈值算法来确定 τ 的最优值, 平衡模型精确率 (precision) 和召回率 (recall)。精确率评估了 TP 样本与所有预测稳定样本的比率, 召回率评估了 TP 样本与实际稳定样本的比率。具体的计算公式如下:

$$Precision(\tau) = \frac{TP(\tau)}{TP(\tau) + FP(\tau)} \quad (6-14)$$

$$Recall(\tau) = \frac{TP(\tau)}{TP(\tau) + FN(\tau)} \quad (6-15)$$

所提阈值选择方法的目标是最大化精确率和召回率的加权和, 该算法的目标函数可以表示为:

$$\max_{\tau} score(\tau) = \alpha \times Precision(\tau) + Recall(\tau) \quad (6-16)$$

其中, $\alpha(>0)$ 是由电力系统运营部门设置的权重, 该权重需要综合考虑安全和经济效益。基于这种方法, 失稳阈值根据不同的 α 值进行自适应调整。

6.4 测试算例分析

6.4.1 数据集生成

本章数据集基于 50 Hz 的 IEEE-39 电力系统生成, 采用 Power System Toolbox 3.0^[123] 工具箱进行暂态稳定性仿真, 并通过精确的时域仿真方法生成数据库。本节中, 电力系统信息特征图 $\mathbf{X} \in \mathbb{R}^{H \times W \times C}$, 以反映电力系统的时空动态, 表示位于 H 个发电机的 W 个时刻的信息, C 表示电气变量类型。 H 设定为 10, W 设定为 10, C 设定为 3, 对应系统中 10 个发电机的相角、有功和无

功率^[71], 包含当前和前序 9 个时刻的信息。

本节考虑了多种运行条件和故障场景, 发电量和负荷在基准值的 80-120% 之间随机变化, 母线电压保持在 0.95-1.05p.u. 之间。在输电线路的 25%、50% 和 70% 处随机施加三相对地短路故障^[134], 故障持续时间设置为 0.10s、0.15s 和 0.20s, 并记录了故障未清除场景下的电气数据, 仿真时长为 10s。样本集中共计 9200 个情景, 其中失稳场景 3892 个。训练集、验证集和测试集按 8:1:1 的比例进行随机划分。本节采用 PyTorch 作为机器学习框架。

本节选取的电气信息可直接由 PMU 收集^[151], 采样频率为每周期一次, 覆盖了故障前、故障持续和故障清除期间。此外, 为确保所模拟的 PMU 数据的真实性, 研究考虑了 PMU 现场数据中的噪声和数据缺失情况^[100], 验证所提算法的实用性。

6.4.2 模型性能

本节建立了两个基于 ViT 结构的分类模型, 分别用于 TSA 任务和失稳发电机机组的识别任务。TSA 包含 2 个 Transformer 子模块, 每个模块有 3 个注意力头。失稳发电机机组识别模型包含 4 个 Transformer 子模块, 每个模块有 3 个注意力头。

对比模型选取深层模型 (CNN、GRU 和 DBN) 和浅层模型 (SVM 和 MLP), 分别面向两个任务进行训练。具体而言, CNN 分类器参考文献[15]建立, 卷积核大小设置为 10×3 , 以捕捉全局特征。MLP 模型参考文献[49]设计, 神经元共计四层, 对于 TSA 模型, 各层神经元数量为 100、50、30 和 5; 对于机组识别模型, 各层神经元数量为 100、50、30 和 10。此外, 在 SVM 和 MLP 中, 电气数据需要被转换为一维向量, 并前置 PCA 以提升性能。模型超参通过网格搜索^[175]确定, 以达到最佳性能。

表 6-1 对比了模型的样本准确率, 而不是场景准确率, 因为本研究采用滑窗持续评估, 每个运行场景具有 490 个滑窗样本。如表 6-1 所示, Transformer 和 CNN 均取得了较高的 TSA 准确率, 表明其在提取暂稳特征方面的优势。相比其他模型, Transformer 在失稳机组识别任务中表现出更高的准确性。此外, SVM 和 MLP 在机组识别任务上的准确率远低于其他模型, 这表明浅层模型的多标签建模能力有限, 不适用于机组识别任务。

与目标检测任务不同, 暂稳评估任务的特征图呈现稠密特性, 特征图中的像素表示系统的运行点, 如图 6-5 所示, 发电机的失稳特征随时间变化更加明显。此外, 如图 6-7 所示, 在不同的失稳状态下可能存在单个或多个失稳机组。因此, 在失稳发电机机组识别任务中, 使用能够保留更高分辨率的算法会更容易

区分失稳和稳定发电机的轨迹，以提高失稳机组识别的准确性。

表 6-1 模型性能对比(%)

Table 6-1 Comparison of model performance (%)		
模型	TSA 准确率	失稳机组识别准确率
MLP ^[49]	94.29	83.13
SVM ^[81]	95.51	84.50
DBN ^[82]	97.23	89.21
GRU ^[176]	97.12	91.29
CNN ^[15]	98.63	91.01
Transformer	98.92	94.21




图 6-7 两类发电机失稳场景

Fig. 6-7 Two types of generator instability scenarios

现有方法中，有研究采用大尺寸卷积核的 CNN 网络来捕获全局信息^[15]，但这会导致模型参数和计算量显著增加^[177]。相比之下，Transformer 不仅能够保持特征图的高分辨率，避免了 CNN 中的显式下采样操作，同时通过注意机制实现像素信息与全局信息的直接交互^[46]。表 6-1 中的结果表明，ViT 模型在 TSA 和失稳机组识别任务中都具有优越的性能。

表 6-2 总结了不同方法的离线训练和在线测试时间，所有计算都在配备 CPU 6240R 2.4G、24C/48T 的服务器上执行。一般来说，浅层算法耗时较少，但准确性相对较低。由于 Transformer 的维度保留特性，其训练耗时高于 CNN。同时，如公式(6-1)所示，所提模型的训练耗时取决于所设定的像素大小。为权衡信息精度和计算效率，本节算法将像素大小设置为 2。

6.4.3 噪声场景下的模型性能对比

在无噪声环境下，模型的性能如表 6-1 所示。由于从 PMU 收集的电气数据会受到广域噪声的影响，确保所提方法能够抵御噪声影响非常重要。根据 IEEE 标准^[135]，PMU 量测误差应小于 1%，对应的信噪比（SNR）为 40dB。此外，本节还对更严重的数据噪声进行测试，即 SNR 值为 10dB 和 20dB^[139]。模型训练时采用无噪声数据，在测试集中加入不同水平的高斯噪声，以评估模型的鲁棒性。

表 6-2 不同算法的耗时对比(s)

Table 6-2 Consumption time comparison of different algorithms (s)				
模型	离线训练		每个样本的在线测试时间	
	TSA	失稳机组	TSA	失稳机组
MLP ^[49]	62.930	133.094	0.012	0.030
SVM ^[81]	42.069	101.039	0.012	0.032
DBN ^[82]	564.102	2600.425	0.129	0.172
GRU ^[176]	583.294	2784.065	0.137	0.167
CNN ^[15]	491.996	2419.827	0.101	0.124
Transformer	610.183	3091.249	0.121	0.142

如表 6-3 和表 6-4 所示，在噪声环境下，每种算法都会有不同程度的准确率下降。结果显示，深层模型对噪声的鲁棒性要优于浅层算法。CNN 通过卷积核的局部感受野和权值共享机制捕获相邻空间上的特征关系。GRU 具有较强的时序建模能力，对时序信息提取准确性较高。在失稳机组识别任务中，准确率的下降程度高于 TSA 任务，由于多标签失稳机组预测任务的复杂性更高。所提模型在两个任务中都呈现出最高的准确性。特别是在失稳机组识别任务中，由于注意力机制能够直接交互不同发电机变量，所提算法的准确性明显高于其他模型。

表 6-3 不同 SNR 水平下的 TSA 模型准确率 (%)

模型	SNR (dB)		
	40	20	10
MLP ^[49]	93.01	92.21	88.21
SVM ^[81]	94.19	93.08	90.69
DBN ^[82]	96.18	95.58	93.33
GRU ^[176]	95.62	94.44	92.98
CNN ^[15]	97.43	97.19	95.47
Transformer	97.89	97.42	96.78

同时，电力系统中的高斯噪声类似于图像分类任务中的纹理噪声（texture noise）。文献[162]证明自注意结构相对于卷积结构更能抵抗纹理噪声，这是由于卷积机制被认为是内容无关（content-independent）的，其过滤器权重共享^[162]。此外，注意力运算可被视为对特征图的可训练空间平滑化（trainable spatial smoothing）^[178]，从而提升了模型在面对高斯噪声时的鲁棒性。

表 6-4 不同 SNR 水平下的失稳机组识别模型准确率 (%)

Table 6-4 Accuracy of unstable unit identification model under different SNR levels (%)

模型	SNR (dB)		
	40	20	10
MLP ^[49]	81.21	80.51	79.33
SVM ^[81]	82.19	81.30	80.99
DBN ^[82]	87.80	86.80	85.03
GRU ^[176]	90.24	88.74	85.63
CNN ^[15]	89.92	88.81	87.25
Transformer	93.12	92.49	90.88

6.4.4 考虑现场数据缺失的模型性能对比

由于广域测量系统中可能出现数据采集单元故障、随机数据丢失等情况^[100, 101]，现场数据的部分丢失会影响 TSA 的在线评估性。根据文献[100]对现场数据的报告，本节随机对 20%的测试样本进行置零，以测试算法在面对数据缺失时的性能。

表 6-5 考虑现场数据缺失的模型性能 (%)

Table 6-5 Model performance considering missing field data (%)

模型	TSA 准确率	失稳机组识别准确率
MLP ^[49]	92.08	83.52
SVM ^[81]	93.22	84.74
DBN ^[82]	95.63	86.76
GRU ^[176]	95.56	90.94
CNN ^[15]	95.03	88.59
Transformer	97.19	94.18

表 6-5 展示了测试数据缺失情况下的模型性能。在数据缺失时，模型需要具有提取长距离依赖和全局关联的建模能力。常见的深层对比模型在完整数据情况下准确率较高，但在数据缺失时性能有所下降。GRU 在数据缺失时准确率明显下降，可能由于其链式结构引发的对缺失信息时序关联的不确定性。浅层模型（如 MLP）对数据缺失更为敏感，性能下降明显。相比其他深层算法，Transformer 模型通过自注意力机制提取全局信息，具有更强的上下文感知能

力。这使 Transformer 在面对数据缺失时能够保持较高的性能，展现出更强的鲁棒性。

6.4.5 最优阈值设置

本节利用来自 10 条不同线路的故障数据，验证所提的失稳阈值自适应优化算法。

如图 6-8 所示，召回率—精度曲线和阈值—精度曲线展示了不同阈值下的 TSA 分类性能。如公式(6-16)所示，通过最大化得分来确定最优失稳阈值。公式(6-16)中的阈值根据不同的权重 α 而改变，召回率和精度则根据公式(6-14)和(6-15)变化。图 6-8 中展示了当 α 分别等于 5 和 30 时，其对应的阈值分别为 0.186 和 0.024。




图 6-8 召回率—精度曲线和阈值—精度曲线
Fig. 6-8 Recall- and threshold-precision curves

在更保守的控制策略下，电力系统运营商将 α 设定为 30，根据公式(6-16)得到最优失稳阈值为 0.024。在这种情况下，失稳漏判样本极少，精度高达 0.987。当样本被判定稳定时，样本的稳定概率 $Pt = T(y=1|X)$ 较高，即该样本的稳定置信水平较高，由此大幅度减少 FP 样本。相反地，如果需要减少误报警导致的经济损失，则接受一定范围内的 FP 样本。此时，可以将 α 设为 5，此时 $\tau=0.186$ ，在 $P_{t=T}(y=0|X)$ 大于 0.186 时发出失稳警告。

综上所述，所提出的暂稳持续预测方法在每周期向电力系统调度部门提供该运行点的失稳概率，调度部门根据实际运行需求来设定 α ，权衡误判率和漏判率。

6.5 算法可拓展性测评：以交直流高压混联系统为例

6.5.1 测试系统与数据生成

本节将所提方法应用于交直流高压混联系统。该系统中两区域的交流电网由一条 500kV 高压直流线路连接，该系统详细参数见 Power System Toolbox 软件^[123]。样本生成规则与 IEEE-39 节点系统相同，故障持续时间 0.15s，仿真时长 10s，并记录故障清除场景的电气信息。该算例共生成了 5000 个场景，包含 2551 个稳定场景和 2449 个失稳场景。

6.5.2 数值测试结果分析

本节将所提算法与 MLP、SVM、DBN、GRU、CNN 算法进行对比，分别在无噪声、测试样本含噪声、测试样本含数据缺失三种场景中测试，以评估所提算法对于交直流电力系统的适用性。

表 6-6 比较了不同模型在 TSA 任务和失稳机组识别任务中的性能。Transformer 模型在两项任务中都达到了最高的准确率，分别为 98.29% 和 95.28%。相对于其他模型，Transformer 能够更有效地捕捉交直流电力系统的复杂动态特征。

表 6-6 模型性能对比 (%)

Table 6-6 Model performance comparison (%)

模型	TSA 准确率	失稳机组识别准确率
MLP ^[49]	93.18	84.62
SVM ^[81]	94.32	85.85
DBN ^[82]	96.73	88.86
GRU ^[176]	96.66	92.04
CNN ^[15]	97.13	89.69
Transformer	98.29	95.28

与传统的 MLP、SVM 等模型相比，深层模型在两项任务中均展现出更高的准确率。在失稳机组识别任务中，GRU 模型准确率较高，说明其在处理时序数据时的优越性；CNN 和 Transformer 模型取得了相对较高的准确率，分别达到了 89.69% 和 95.28%，表明深层结构对失稳机组识别的优越性。

如表 6-7 所示，在 SNR 为 40dB 的噪声场景下，所有模型的性能都受到了一定程度的影响。在失稳机组识别任务中，相比其他算法，Transformer 和 GRU 在保持了较高的识别准确率，说明 GRU 中的时序提取结构和 Transformer 中的注意力机制面向交直流电气数据依然有效。其中，Transformer 模型的

TSA 准确率（97.69%）和失稳机组识别准确率（94.68%）最高，其内置的注意力机制使模型关注关键特征，提升对输入序列的自适应建模能力，由此抵御噪声干扰，证明所提算法在面向高噪声场景下的鲁棒性。

表 6-7 在 SNR=40dB 的噪声下的模型性能对比(%)

Table 6-7 Comparison of model performance under noise level at SNR=40dB (%)

模型	TSA 准确率	失稳机组识别准确率
MLP ^[49]	92.58	83.98
SVM ^[81]	93.76	85.45
DBN ^[82]	96.13	87.30
GRU ^[176]	96.06	91.44
CNN ^[15]	96.53	89.09
Transformer	97.69	94.68

表 6-8 在交直流系统下进行样本缺失 20%时的模型性能对比。分析可知，缺失数据导致所有模型的性能不同程度下降。其中，相比浅层算法，DBN 和 GRU 的准确率仍然较高，表明其具备良好的时序信息建模能力；CNN 通过池化层中的信息降维操作，对数据缺失情况具有一定的鲁棒性。然而，相比于 Transformer，CNN 更易受制于局部特征的建模，对全局信息捕捉能力不足，导致其对失稳机组的识别准确性较低。Transformer 模型在处理缺失数据方面表现出较强的鲁棒性，通过全局感知能力和注意力自适应性，保持其对交直流系统复杂特性的建模能力。

表 6-8 在测试样本 20%缺失下的模型性能对比 (%)

Table 6-8 Comparison of model performance with 20% missing of the test samples (%)

模型	TSA 准确率	失稳机组识别准确率
MLP ^[49]	91.98	83.38
SVM ^[81]	93.16	84.85
DBN ^[82]	95.53	86.70
GRU ^[176]	95.46	90.84
CNN ^[15]	95.93	88.49
Transformer	97.09	94.08

6.6 本章小结

本章主要解决以下问题：1) 在实际应用中，由于电气设备与 PMU 中的时钟误差，现有数据驱动的 TSA 模型难以获取准确的故障发生和消除时刻，导致模型性能下降；2) 继保拒动下故障无法正确清除，因此常见的由故障清除信号激活的 TSA 模型无法正确启动，无法提供暂态失稳预警；3) 失稳发电机识别的模型准确率较低；4) 基于专家经验设置的失稳阈值判定标准较为主观，

无法提供精确的判定标准。

为解决上述问题，本章提出了一种基于 ViT 机制的两阶段在线监测方法，实现暂态稳定性评估和失稳发电机组的预测。暂态稳定性评估方案根据当前运行点提供暂态状态，无需依赖故障发生或清除信号，并且适用于继电器失效场景。本章对比实验表明，提出的方法在准确性和鲁棒性方面优于现有方法，在 PMU 噪声和数据缺失情况下均能维持良好性能。对于失稳发电机组的识别任务，由于引入了注意力机制，模型性能的改进尤为显著。最后，为了得到不同决策保守度下的失稳判定阈值，提出一种自适应调整的失稳阈值设定算法，以进一步增加算法的适用性。

第7章 总结和展望

7.1 研究工作总结

随着现代电网建设的不断推进,我国电力系统已经发展成为规模庞大、结构复杂,多源信息交互的复杂信息物理系统。传统的基于物理模型的暂态分析方法难以满足新形态复杂电力系统安全评估需求。由于实时信息收集设备和智能算法等新兴技术的迅速发展,本文采用深度学习的数据驱动方法,深入研究了电力系统暂态稳定评估问题,主要研究内容包括边界样本生成方法、在线应用时缺失数据的重建方法、可解释性暂稳模型的构建方法等,最终旨在提高稳定评估模型的训练效率、可靠性和适用性。相关研究工作总结如下:

针对安全域下的临界样本匮乏导致模型对安全边界刻画能力不足的问题,第二章提出了基于生成对抗机制的安全边界样本生成方法。该方法将基于卷积机制的监督模型融入生成对抗结构,并通过提出考虑样本与分类边界距离的损失函数,生成大量生成电力系统安全边界附近样本。仿真结果表明,相较于现有方法,该算法能够生成更真实且靠近分类边界的样本。通过对生成样本的直观可视化,展示了这些样本的分布集中在电力系统安全边界附近。最后,通过所提方法增强训练集,能够减少 DSA 模型对训练数据量的需求,并保持较高的分类准确性,证明生成的样本能够提升 DSA 模型的训练效率,并提升 DSA 模型对安全稳定知识的学习和提取能力。

针对暂稳评估任务中失稳样本量不足且模型对临界失稳样本识别能力不足的问题,第三章提出了稳定域下的失稳样本集合生成方法,旨在提高数据驱动暂稳评估模型的性能。该方法将映射故障清除时刻的电气量与失稳时间之间关系的回归模型融入到生成 GAN 结构中,并通过改进生成器损失函数,最终构建能够生成大量临界失稳样本的生成算法。实验结果表明,与现有方法相比,该算法能够生成更真实且失稳时刻更长的失稳样本。通过在暂态稳定性评估模型中验证,该方法生成的数据集显著提升了模型对失稳样本的识别能力。

针对在线量测数据的数据缺失导致 TSA 模型性能下降的问题,第四章提出了基于生成对抗结构的缺失数据重建模型。通过消融实验验证了所提出的模型结构和损失函数的有效性。实验结果表明,在随机数据缺失和 PMU 故障场景下,与现有方法相比,所提模型具有更高的数据重建准确度。此外,所提方法具有一定的可解释性,模型内部参数分布证明模型能够自适应地关注有效数据且避开无效信息,进一步增强了在实际应用中的可信度。此外,第四章还提

出一个用于 TSA 任务的在线框架，证明所提数据重建方法在 TSA 任务中的有效性和必要性。最后，该数据重建方法可以通过调整输入特征的参数以满足不同任务需求，应用于其他的电力系统数据驱动任务中，具有广泛的应用潜力。

针对现有暂态评估模型可解释性低导致模型难以被信任的问题，第五章提出了基于自注意力编码器的暂稳多阶段预测模型。该方法采用底层量测数据预测系统暂稳状态，在准确性和鲁棒性上优于常见算法。同时，该方法展现出良好的可解释性，通过展现深层网络内部工作过程，证明模型在训练迭代中能够自适应关注并聚焦于重要特征，所提算法呈现的内部参数分布符合实际系统的物理关系，提高了算法决策的可信度，并给未来的数据收集提供了方向。

针对现有暂态评估模型需要准确的故障清除时刻信息，因此受电气设备间时钟误差和继保信号影响的问题，第六章提出了基于 Vision-Transformer 网络的在线暂稳监测方法，旨在实现暂态稳定性评估和失稳发电机组的预测。该系统根据当前操作点提供暂稳状态，无需依赖故障发生或清除信号，同时适用于继电器失效场景。实验结果表明，所提出的方法在准确性和鲁棒性方面优于现有方法。尤其对于失稳机组的预测任务，由于引入了注意力机制，模型性能的改进尤为显著。最后，为了得到不同决策保守度下的失稳判定阈值，提出一种自适应调整的失稳阈值设定算法，以进一步增加算法的适用性。

7.2 后续工作展望

本文采用深度学习方法对电力系统暂态稳定评估相关问题进行了研究，成果仍存在改进的空间和待进一步开展的工作。后续的研究展望如下：

(1) 本文所提方法已被证明在时空相关的场景中有效，能够成功重建缺失的 PMU 数据，有望扩展并解决智能电网中其他缺失数据重建任务。然而，由于 PMU 部署的成本较高，目前电力系统中的在线测量数据主要来源于 PMU 和 SCADA 系统数据的整合，由于两类数据采集装置具有不同的采样率，这种数据整合方式可能会带来新的问题。因此，未来的工作将探索如何建立多源异构数据的统一表征方法，通过特征工程来提取和构建适用于模型的特征。这可能涉及到特征选择、降维、转换和衍生等技术，以提升数据驱动模型对于数据的利用效率，并将本文所提方法扩展来处理这种整合下的特征数据。

(2) 当前的研究在电力系统分析方面取得了一定进展，但随着电网规模的扩大，模型的训练面临巨大挑战。随着电网规模的不断扩大和 PMU 节点的增加，模型特征图的尺寸急剧增加，神经网络的训练和优化变得困难。为了应对这一挑战，有必要将物理约束与数据驱动方法相结合。未来的工作包括如何在模型训练中引入电网的物理逻辑和相关的时间或空间约束，构建能够提取最

关键物理知识的特征图，以提高模型的训练效率和泛化能力。此外，还需要研究具有更强迁移能力的 GAN 网络，以确保在应用于超出训练集范围的电力系统运行点时，数据重建仍然有效。

(3) 目前，在电力系统领域中，已经涌现出许多基于深度学习的方法，用于判断稳定性、重建暂态时空数据和生成暂态数据等任务。这些任务采用独立且不关联的方式分别训练了多个模型，需要大量数据资源和计算资源。因此，未来的研究将探索建立适用于多种电力系统暂态稳定分析相关任务的综合模型，通过多种任务的联合训练方式提升人工智能对复杂电力系统动态响应的理解和刻画能力，并减少人工智能应用的成本。

参考文献

- [1] 刘振亚. 全球能源互联网跨国跨洲互联研究及展望[J]. 中国电机工程学报, 2016,36(19): 5103--5110
- [2] 孙华东, 许涛, 郭强, 等. 英国“8·9”大停电事故分析及对中国电网的启示[J]. 中国电机工程学报, 2019,39(21): 6183-6191
- [3] 舒印彪, 张智刚, 郭剑波, 等. 新能源消纳关键因素分析及解决措施研究[J]. 中国电机工程学报, 2017,37(1): 1-8
- [4] 曾令康. 基于强化学习的复杂电力系统安全评估与稳定控制[D]. 华中科技大学, 2022
- [5] 刘洋洋. 基于深度学习的电力系统暂态稳定控制技术研究[D]. 东南大学, 2022
- [6] LeCun Y., Bengio Y., Hinton G. Deep Learning[J]. nature, 2015,521(7553): 436-444
- [7] 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
- [8] 周毅博. 数据驱动的电力系统暂态稳定评估变量间关联及因果关系表征识别方法研[D]. 东北电力大学, 2023
- [9] 颜融. 基于数据驱动的电力系统暂态稳定评估[D]. 浙江大学, 2021
- [10] 中华人民共和国国家标准: 电力系统安全稳定导则. GB 38755-2019[S]. 2019
- [11] Yu Y., Liu Y., Qin C., et al. Theory and Method of Power System Integrated Security Region Irrelevant to Operation States: An Introduction[J]. Engineering, 2020,6(7): 754-777
- [12] Liu J., Sun H., Li Y., et al. An Improved Power System Transient Stability Prediction Model Based on mRMR Feature Selection and WTA Ensemble Learning[J]. Applied Sciences, 2020,10(7): 2255
- [13] Li Q., Xu Y., Ren C., et al. A Hybrid Data-Driven Method for Online Power System Dynamic Security Assessment with Incomplete PMU Measurements[A]. 2019 IEEE power & energy society general meeting (PESGM)[C]. 2019: 1-5
- [14] Huang J.-T. Global Tracking Control of Strict-Feedback Systems Using Neural Networks[J]. IEEE transactions on neural networks and learning systems, 2012,23(11): 1714-1725
- [15] Gupta A., Gurrula G., Sastry P. S. An Online Power System Stability Monitoring System Using Convolutional Neural Networks[J]. IEEE Transactions on Power Systems, 2019,34(2): 864-872
- [16] 王锡凡. 现代电力系统分析[M]. 北京: 科学出版社, 2015: 292-310
- [17] Wu Z., Zhou X. Power System Analysis Software Package (PSASP)-an

- Integrated Power System Analysis Tool[A]. POWERCON '98. 1998 international conference on power system technology. Proceedings (cat. No.98EX151): Vol. 1[C]. 1998: 7-11
- [18] Zheng Z., Wu M., Chen J., et al. Comparative Analysis of the Application of BPA and PSCAD in Voltage Sag Simulation[J]. IOP Conference Series: Earth and Environmental Science, 2020,617(1): 012021
- [19] Jiang Q., Peng X., Zhang B. PSS/E - An Advanced Software Package for Power System Analysis and Simulation[J]. High Voltage Engineering, 2005,31(1): 60-62
- [20] Bobric E., Irimia D., Rata G., et al. Planning and Management of the Power System Using DsatoolTM Software[J]. ANNALS OF THE ORADEA UNIVERSITY. Fascicle of Management and Technological Engineering., 2010,XIX (IX), 2010/1
- [21] 夏世威, 白雪峰, 陈士麟, 等. 多群模式 Taylor 级数法暂态稳定计算[J]. 电力系统自动化, 2010,34(10): 24-28
- [22] 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(07): 36-41
- [23] 苏福, 杨松浩, 王怀远, 等. 电力系统暂态稳定时域仿真快速终止算法研究[J]. 中国电机工程学报, 2017,37(15): 4372-4378+4577
- [24] Magnusson P. C. The Transient-Energy Method of Calculating Stability[J]. Transactions of the American Institute of Electrical Engineers, 1947,66(1): 747-755
- [25] Aylett P. The Energy-Integral Criterion of Transient Stability Limits of Power Systems[J]. Proceedings of the IEE-Part C: Monographs, 1958,105(8): 527-536
- [26] Gless G. Direct Method of Liapunov Applied to Transient Power System Stability[J]. IEEE Transactions on Power Apparatus and Systems, 1966(2): 159-168
- [27] Ahmed H. E., K. N. Transient Stability Regions of Multimachine Power Systems[J]. IEEE Transactions on Power Apparatus and Systems, 1966,PAS-85(2): 169-179
- [28] Fouad A., Lugtu R. Transient Stability Analysis of Power-Systems Using Liapunovs Second Method[A]. IEEE Paper No. C72 145-6[C]. 1972: 1
- [29] Chiang H., Thorp J. S. The Closest Unstable Equilibrium Point Method for Power System Dynamic Security Assessment[A]. 26th IEEE conference on decision and control: Vol. 26[C]. IEEE, 1987: 72-76
- [30] Kakimoto N. Transient Stability Analysis of Electric Power System Via Lur'e Type Lyapunov Function[J]. Trans. IEE of Japan, 1978,98(5/6): 63-79
- [31] Chiang H.-D., Wu F., Varaiya P. Foundations of Direct Methods for Power

- System Transient Stability Analysis[J]. IEEE Transactions on Circuits and systems, 1987,34(2): 160-173
- [32] Chiang H.-D., Wu F. F., Varaiya P. P. Foundations of the Potential Energy Boundary Surface Method for Power System Transient Stability Analysis[J]. IEEE Transactions on circuits and systems, 1988,35(6): 712-728
- [33] Xue Y., Van Cutsem T., Ribbens-Pavella M. A Simple Direct Method for Fast Transient Stability Assessment of Large Power Systems[J]. IEEE Transactions on Power Systems, 1988,3(2): 400-412
- [34] 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
- [35] Xue Y., Wehenkel L., Belhomme R., et al. Extended Equal Area Criterion Revisited (EHV Power Systems)[J]. IEEE Transactions on Power Systems, 1992,7(3): 1012-1022
- [36] 薛禹胜. Deac 的理论证明——四论暂态能量直接法[J]. 电力系统自动化, 1993,17(7): 7-19
- [37] 常乃超, 兰洲, 甘德强, 等. 广域测量系统在电力系统分析及控制中的应用综述[J]. 电网技术, 2005,29(10): 46-52
- [38] 秦晓辉, 毕天姝, 杨奇逊, 等. 基于 WAMS 动态轨迹的电力系统功角失稳判据[J]. 电力系统自动化, 2008,32(23): 18-22
- [39] 赵磊, 单渊达. 基于轨迹信息的发电机暂态稳定指标分析方法[J]. 电网技术, 2002,26(8): 25-28
- [40] Okuda T., Nakagawa S., Iwamoto S. A Transient Stability Evaluation Method Based on Kinetic Energy of Post-Fault Trajectories[A]. IEEE PES power systems conference and exposition[C]. 2006: 1280-1285
- [41] 宋方方, 毕天姝, 杨奇逊. 基于暂态能量变化率的电力系统多摆稳定性判别[J]. 中国电机工程学报, 2007,27(16): 13-18
- [42] 谢欢, 张保会, 于广亮, 等. 基于相轨迹凹凸性的电力系统暂态稳定性识别[J]. 中国电机工程学报, 2006,26(5): 38-42
- [43] 王科, 游大海, 陈震海, 等. 基于改进位能脊的电力系统暂态稳定快速识别算法[J]. 电网技术, 2011,35(12): 89-93
- [44] 顾卓远, 汤涌, 孙华东, 等. 一种基于转速差-功角差变化趋势的暂态功角稳定辨识方法[J]. 中国电机工程学报, 2013,33(31): 65-72
- [45] Tolle K. M., Tansley D. S. W., Hey A. J. The Fourth Paradigm: Data-Intensive Scientific Discovery [Point of View][J]. Proceedings of the IEEE, 2011,99(8): 1334-1337
- [46] Vaswani A., Shazeer N., Parmar N., et al. Attention Is All You Need[A].

- Advances in neural information processing systems: Vol. 30[C]. 2017: 1-11
- [47] Chen K., Hu J., He J. A Framework for Automatically Extracting Overvoltage Features Based on Sparse Autoencoder[J]. IEEE Transactions on Smart Grid, 2016,9(2): 594-604
- [48] Chen K., He Z., Wang S. X., et al. Learning-Based Data Analytics: Moving Towards Transparent Power Grids[J]. CSEE Journal of Power and Energy Systems, 2018,4(1): 67-82
- [49] Zhou Y., Guo Q., Sun H., 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(1): 379-394
- [50] Gomez F. R., Rajapakse A. D., Annakkage U. D., et al. Support Vector Machine-Based Algorithm for Post-Fault Transient Stability Status Prediction Using Synchronized Measurements[J]. IEEE Transactions on Power Systems, 2011,26(3): 1474-1483
- [51] 周艳真, 吴俊勇, 冀鲁豫, 等. 基于两阶段支持向量机的电力系统暂态稳定预测及预防控制[J]. 中国电机工程学报, 2018,38(1): 137-147
- [52] Guo T., Milanović J. V. Probabilistic Framework for Assessing the Accuracy of Data Mining Tool for Online Prediction of Transient Stability[J]. IEEE Transactions on Power Systems, 2013,29(1): 377-385
- [53] Samantaray S. R., Kamwa I., Joos G. Phasor Measurement Unit Based Wide-Area Monitoring and Information Sharing Between Micro-Grids[J]. IET Generation, Transmission & Distribution, 2017,11(5): 1293-1302
- [54] Douzas G., Bacao F., Last F. Improving Imbalanced Learning Through a Heuristic Oversampling Method Based on K-Means and SMOTE[J]. Information Sciences, 2018,465(1): 1-20
- [55] Tan B., Yang J., Tang Y., et al. A Deep Imbalanced Learning Framework for Transient Stability Assessment of Power System[J]. IEEE access : practical innovations, open solutions, 2019,7(1): 81759-81769
- [56] Chawla N. V., Bowyer K. W., Hall L. O., et al. SMOTE: Synthetic Minority Over-Sampling Technique[J]. Journal of Artificial Intelligence Research, 2002,16(1): 321-357
- [57] Shao S., Wang P., Yan R. Generative Adversarial Networks for Data Augmentation in Machine Fault Diagnosis[J]. Computers in Industry, 2019,106(1): 85-93
- [58] Liu J., Qu F., Hong X., et al. A Small-Sample Wind Turbine Fault Detection Method With Synthetic Fault Data Using Generative Adversarial Nets[J]. IEEE Transactions on Industrial Informatics, 2019,15(7): 3877-3888
- [59] Ren C., Xu Y. A Fully Data-Driven Method Based on Generative Adversarial

- Networks for Power System Dynamic Security Assessment With Missing Data[J]. IEEE Transactions on Power Systems, 2019,34(6): 5044-5052
- [60] Li J., Yang H., Yan L., et al. Data Augment Using Deep Convolutional Generative Adversarial Networks for Transient Stability Assessment of Power Systems[A]. 2020 39th Chinese Control Conference (CCC)[C]. 2020: 6135-6140
- [61] Zhu L., Hill D. J. Data/Model Jointly Driven High-Quality Case Generation for Power System Dynamic Stability Assessment[J]. IEEE Transactions on Industrial Informatics, 2022,18(8): 5055-5066
- [62] 杨东升, 吉明佳, 周博文, 等. 基于双生成器生成对抗网络的电力系统暂态稳定评估方法[J]. 电网技术, 2021,45(8): 2934-2945
- [63] 周艳真, 吴俊勇, 于之虹, 等. 用于电力系统暂态稳定预测的支持向量机组组合分类器及其可信度评价[J]. 电网技术, 2017,41(4): 1188-1196
- [64] Zhang R., Wu J., Shao M., et al. Transient Stability Prediction of Power Systems Based on Deep Belief Networks[A]. 2018 2nd IEEE conference on energy internet and energy system integration (EI2)[C]. IEEE, 2018: 1-6
- [65] Frimpong E. A., Okyere P. Y., Asumadu J. On-Line Determination of Transient Stability Status Using Multilayer Perceptron Neural Network[J]. Journal of Electrical Engineering, 2018,69(1): 58-64
- [66] 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
- [67] Hang F., Huang S., Chen Y., et al. Power System Transient Stability Assessment Based on Dimension Reduction and Cost-Sensitive Ensemble Learning[A]. 2017 IEEE conference on energy internet and energy system integration (EI2)[C]. IEEE, 2017: 1-6
- [68] 石访, 张林林, 胡熊伟, 等. 基于多属性决策树的电网暂态稳定规则提取方法[J]. 电工技术学报, 2019,34(11): 2364-2374
- [69] 顾雪平, 张文朝. 基于 tabu 搜索技术的暂态稳定分类神经网络的输入特征选择[J]. 中国电机工程学报, 2002,22(7): 66-70
- [70] 王亚俊, 王波, 唐飞, 等. 基于响应轨迹和核心向量机的电力系统在线暂态稳定评估[J]. 中国电机工程学报, 2014,34(19): 3178-3186
- [71] Tan B., Yang J., Zhou T., et al. Spatial-Temporal Adaptive Transient Stability Assessment for Power System Under Missing Data[J]. International Journal of Electrical Power & Energy Systems, 2020,123(1): 106237
- [72] Kamwa I., Samantaray S., Joos G. Development of Rule-Based Classifiers for Rapid Stability Assessment of Wide-Area Post-Disturbance Records[J]. IEEE Transactions on Power Systems, 2009,24(1): 258-270

- [73] 周艳真, 吴俊勇, 于之虹, 等. 基于转子角轨迹簇特征的电力系统暂态稳定评估[J]. 电网技术, 2016,40(5): 1482-1487
- [74] Zhang C., Li Y., Yu Z., et al. Feature Selection of Power System Transient Stability Assessment Based on Random Forest and Recursive Feature Elimination[A]. 2016 IEEE PES asia-pacific power and energy engineering conference (APPEEC)[C]. IEEE, 2016: 1264-1268
- [75] 邬春明, 任继红. 基于 XGBoost-EE 的电力系统暂态稳定评估方法[J]. 电力自动化设备, 2021,41(2): 138-143
- [76] 钱倍奇, 陈谦, 张政伟, 等. 基于异构数据特征级融合的多任务暂态稳定评估[J]. 电力系统自动化, 2023,47(09): 118-128
- [77] Sun M., Konstantelos I., Strbac G. A Deep Learning-Based Feature Extraction Framework for System Security Assessment[J]. IEEE transactions on smart grid, 2018,10(5): 5007-5020
- [78] Sobajic D. J., Pao Y.-H. Artificial Neural-Net Based Dynamic Security Assessment for Electric Power Systems[J]. IEEE Transactions on power Systems, 1989,4(1): 220-228
- [79] Rovnyak S., Kretsinger S., Thorp J., et al. Decision Trees for Real-Time Transient Stability Prediction[J]. IEEE Transactions on Power Systems, 1994,9(3): 1417-1426
- [80] Moulin L., Da Silva A. A., El-Sharkawi M., et al. Support Vector Machines for Transient Stability Analysis of Large-Scale Power Systems[J]. IEEE Transactions on Power systems, 2004,19(2): 818-825
- [81] Guo T., Milanović J. V. Online Identification of Power System Dynamic Signature Using PMU Measurements and Data Mining[J]. IEEE Transactions on Power Systems, 2016,31(3): 1760-1768
- [82] Wu S., Zheng L., Hu W., et al. Improved Deep Belief Network and Model Interpretation Method for Power System Transient Stability Assessment[J]. Journal of Modern Power Systems and Clean Energy, 2020,8(1): 27-37
- [83] James J., Hill D. J., Lam A. Y., et al. Intelligent Time-Adaptive Transient Stability Assessment System[J]. IEEE Transactions on Power Systems, 2017,33(1): 1049-1058
- [84] 王怀远, 陈启凡. 基于代价敏感堆叠变分自动编码器的暂态稳定评估方法[J]. 中国电机工程学报, 2020,40(7): 2213-2220
- [85] Tan B., Yang J., Pan X., et al. Representational Learning Approach for Power System Transient Stability Assessment Based on Convolutional Neural Network[J]. The Journal of Engineering, 2017,2017(13): 1847-1850
- [86] Hu B., Hao Z., Chen Z., et al. Combination with Continual Learning Update Scheme for Power System Transient Stability Assessment[J]. Sensors,

- 2022,22(22): 8982
- [87] Gu S., Qiao J., Zhao Z., et al. Power System Transient Stability Assessment Based on Graph Neural Network with Interpretable Attribution Analysis[A]. 2022 4th international conference on smart power & internet energy systems (SPIES)[C]. IEEE, 2022: 1374-1379
- [88] 王铮澄, 周艳真, 郭庆来, 等. 考虑电力系统拓扑变化的消息传递图神经网络暂态稳定评估[J]. 中国电机工程学报, 2021,41(7): 2341-2350
- [89] 钟智, 管霖, 苏寅生, 等. 基于图注意力深度网络的电力系统暂态稳定评估[J]. 电网技术, 2021,45(6): 2122-2130
- [90] Chen Z., Ren C., Xu Y. An Improved AdaBoost-Based Ensemble Learning Method for Data-Driven Dynamic Security Assessment of Power Systems[A]. 2022 IEEE power & energy society general meeting (PESGM)[C]. 2022: 1-5
- [91] 戴远航, 陈磊, 张玮灵, 等. 基于多支持向量机综合的电力系统暂态稳定评估[J]. 中国电机工程学报, 2016,36(5): 1173-1180
- [92] 田芳, 周孝信, 史东宇, 等. 基于卷积神经网络综合模型和稳态特征量的电力系统暂态稳定评估[J]. 中国电机工程学报, 2019,39(14): 4025-4032
- [93] 张翌晖, 张元胜, 文立斌, 等. 基于多 RBF-ELM 集成模型的电力系统暂态稳定评估[J]. 武汉大学学报 (工学版), 2021,54(9): 852-859
- [94] 吴思婕, 王怀远. 基于集成学习的时间自适应电力系统暂态稳定评估方法[J]. 电力系统保护与控制, 2022,50(24): 112-119
- [95] Zheng L., Wang Z., Li G., et al. Evaluating the Significance of Samples in Deep Learning-Based Transient Stability Assessment[J]. Frontiers in Energy Research, 2022,10(1): 925126
- [96] Genc I., Diao R., Vittal V., et al. Decision Tree-Based Preventive and Corrective Control Applications for Dynamic Security Enhancement in Power Systems[J]. IEEE Transactions on Power Systems, 2010,25(3): 1611-1619
- [97] Liu C., Sun K., Rather Z. H., et al. A Systematic Approach for Dynamic Security Assessment and the Corresponding Preventive Control Scheme Based on Decision Trees[J]. IEEE Transactions on Power Systems, 2013,29(2): 717-730
- [98] Thams F., Venzke A., Eriksson R., et al. Efficient Database Generation for Data-Driven Security Assessment of Power Systems[J]. IEEE Transactions on Power Systems, 2019,35(1): 30-41
- [99] Krishnan V., McCalley J. D., Henry S., et al. Efficient Database Generation for Decision Tree Based Power System Security Assessment[J]. IEEE Transactions on Power systems, 2011,26(4): 2319-2327
- [100] Zhu L., Hill D. J. Cost-Effective Bad Synchrophasor Data Detection Based on Unsupervised Time-Series Data Analytic[J]. IEEE Internet of Things Journal,

- 2021,8(3): 2027-2039
- [101]Liao W., Salinas S., Li M., et al. Cascading Failure Attacks in the Power System: A Stochastic Game Perspective[J]. IEEE Internet of Things Journal, 2017,4(6): 2247-2259
- [102]Zhang Y., Xu Y., Dong Z. Y. Robust Ensemble Data Analytics for Incomplete Pmu Measurements-Based Power System Stability Assessment[J]. IEEE Transactions on Power Systems, 2018,33(1): 1124-1126
- [103]Zhang Y., Xu Y., Dong Z. Y. Robust Classification Model for PMU-Based on-Line Power System DSA with Missing Data[J]. IET Generation, Transmission & Distribution, 2017,11(18): 4484-4491
- [104]Gao P., Wang M., Ghiocel S. G., et al. Missing Data Recovery by Exploiting Low-Dimensionality in Power System Synchrophasor Measurements[J]. IEEE Transactions on Power Systems, 2016,31(2): 1006-1013
- [105]Hao Y., Wang M., Chow J. H. Modeless Streaming Synchrophasor Data Recovery in Nonlinear Systems[J]. IEEE Transactions on Power Systems, 2020,35(2): 1166-1177
- [106]Liao M., Shi D., Yu Z., et al. An Alternating Direction Method of Multipliers Based Approach for PMU Data Recovery[J]. Smart Grid, IEEE Transactions on, 2019,10(4): 4554-4565
- [107]Yu J. J. Q., Lam A. Y. S., Hill D. J., et al. Delay Aware Power System Synchrophasor Recovery and Prediction Framework[J]. IEEE Transactions on Smart Grid, 2019,10(4): 3732-3742
- [108]Guo X., Zhu S., Yang Z., et al. Consecutive Missing Data Recovery Method Based on Long-Short Term Memory Network[A]. 2021 3rd asia energy and electrical engineering symposium (AEEES)[C]. 2021: 988-992
- [109]Goodfellow I., Pouget-Abadie J., Mirza M., et al. Generative Adversarial Networks[J]. Communications of the ACM, 2020,63(11): 139-144
- [110]陈明华, 刘群英, 张家枢, 等. 基于 XGBoost 的电力系统暂态稳定预测方法[J]. 中国电机工程学报, 2020,44(3): 1026-1034
- [111]韩天森, 陈金富, 李银红, 等. 电力系统稳定评估机器学习可解释代理模型研究[J]. 中国电机工程学报, 2020,40(13): 4122-4130
- [112]周挺, 杨军, 詹祥澎, 等. 一种数据驱动的暂态电压稳定评估方法及其可解释性研究[J]. 电网技术, 2021,45(11): 4416-4425
- [113]Zeiler M. D., Fergus R. Visualizing and Understanding Convolutional Networks[A]. Computer Vision—ECCV 2014: 13th european conference, zurich, switzerland, september 6-12, 2014, proceedings, part I 13[C]. Springer, 2014: 818-833
- [114]Simonyan K., Vedaldi A., Zisserman A. Deep Inside Convolutional Networks:

- Visualising Image Classification Models and Saliency Maps[EB/OL]. arXiv preprint arXiv:1312.6034, 2013
- [115]Sundararajan M., Taly A., Yan Q. Axiomatic Attribution for Deep Networks[A]. International conference on machine learning[C]. PMLR, 2017: 3319-3328
- [116]Zhou B., Khosla A., Lapedriza A., et al. Learning Deep Features for Discriminative Localization[A]. Proceedings of the IEEE conference on computer vision and pattern recognition[C]. 2016: 2921-2929
- [117]Chattopadhyay A., Sarkar A., Howlader P., et al. Grad-Cam++: Generalized Gradient-Based Visual Explanations for Deep Convolutional Networks[A]. 2018 IEEE winter conference on applications of computer vision (WACV)[C]. 2018: 839-847
- [118]Ioffe S., Szegedy C. Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift[A]. International conference on machine learning[C]. pmlr, 2015: 448-456
- [119]Ulyanov D., Vedaldi A., Lempitsky V. Instance Normalization: The Missing Ingredient for Fast Stylization[EB/OL]. arXiv preprint arXiv: 1607.08022, 2017
- [120]Mao X., Li Q., Xie H., et al. Least Squares Generative Adversarial Networks[A]. 2017 IEEE International Conference on Computer Vision (ICCV)[C]. 2017: 2813-2821
- [121]Lv J., Pawlak M., Annakkage U. D. Prediction of the Transient Stability Boundary Based on Nonparametric Additive Modeling[J]. IEEE Transactions on Power Systems, 2017,32(6): 4362-4369
- [122]Yan R., Geng G., Jiang Q. Data-Driven Transient Stability Boundary Generation for Online Security Monitoring[J]. IEEE Transactions on Power Systems, 2021,36(4): 3042-3052
- [123]Chow J. H., Cheung K. W. A Toolbox for Power System Dynamics and Control Engineering Education and Research[J]. IEEE transactions on Power Systems, 1992,7(4): 1559-1564
- [124]Kundur P. S., Malik O. P. Power System Stability and Control[M]. New York: McGraw-Hill Education, 2022:18-26
- [125]AN J., MU G., LI Z., et al. Power System Transient Stability Margin Assessment Using Steady-State Information[A]. 2019 IEEE innovative smart grid technologies - asia (ISGT asia)[C]. 2019: 642-647
- [126]He K., Zhang X., Ren S., et al. Deep Residual Learning for Image Recognition[EB/OL]. arXiv preprint arXiv:1512.03385, 2015
- [127]Srivastava N., Hinton G., Krizhevsky A., et al. Dropout: A Simple Way to Prevent Neural Networks from Overfitting[J]. Journal of Machine Learning Research, 2014,15(56): 1929-1958

- [128]Heusel M., Ramsauer H., Unterthiner T., et al. GANs Trained by a Two Time-Scale Update Rule Converge to a Local Nash Equilibrium[EB/OL]. .arXiv preprint arXiv:1706.08500, 2017
- [129]Kolarik M., Burget R., Riha K. Comparing Normalization Methods for Limited Batch Size Segmentation Neural Networks[A]. 2020 43rd international conference on telecommunications and signal processing (TSP)[C]. IEEE, 2020: 677-680
- [130]Xu B., Wang N., Chen T., et al. Empirical Evaluation of Rectified Activations in Convolutional Network[EB/OL]. .arXiv preprint arXiv: 1505.00853, 2015
- [131]Zhang H., Goodfellow I., Metaxas D., et al. Self-Attention Generative Adversarial Networks[A]. International conference on machine learning[C]. PMLR, 2019: 7354-7363
- [132]Tang Y., Huang Y., Wang H., et al. Framework for Artificial Intelligence Analysis in Large-Scale Power Grids Based on Digital Simulation[J]. CSEE Journal of Power and Energy Systems, 2018,4(4): 459-468
- [133]Wang X., Girshick R., Gupta A., et al. Non-Local Neural Networks[A]. Proceedings of the IEEE conference on computer vision and pattern recognition[C]. 2018: 7794-7803
- [134]Gupta A., Gurrala G., Sastry P. S. Instability Prediction in Power Systems Using Recurrent Neural Networks[A]. IJCAI international joint conference on artificial intelligence[C]. International Joint Conferences on Artificial Intelligence, 2017: 1795-1801
- [135]IEEE Std C37.118.2-2011, Ieee Standard for Synchrophasor Data Transfer for Power Systems[S]. 2011
- [136]Friday Zinzendoff O., Bolaji A., Arunaye F. Breakdown Analysis of Pearson Correlation Coefficient and Robust Correlation Methods[J]. IOP Conference Series: Materials Science and Engineering, 2020,917(1): 012065
- [137]Nguyen T. T., Luong A. V., Dang M. T., et al. Ensemble Selection Based on Classifier Prediction Confidence[J]. Pattern Recognition, 2020,100(1): 107104
- [138]Zimmerman R. D., Murillo-Sánchez C. E., Thomas R. J. MATPOWER: Steady-State Operations, Planning, and Analysis Tools for Power Systems Research and Education[J]. IEEE Transactions on Power Systems, 2011,26(1): 12-19
- [139]Chen K., Hu J., He J. Detection and Classification of Transmission Line Faults Based on Unsupervised Feature Learning and Convolutional Sparse Autoencoder[J]. IEEE Transactions on Smart Grid, 2018,9(3): 1748-1758
- [140]Yan C., Chang X., Li Z., et al. Zeronas: Differentiable Generative Adversarial Networks Search for Zero-Shot Learning[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2022,44(12): 9733-9740
- [141]Yan C., Chang X., Luo M., et al. Semantics-Guided Contrastive Network for

- Zero-Shot Object Detection[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2024,46(3): 1530-1544
- [142]Ouyang X., Chen Y., Agam G. Accelerated WGAN Update Strategy with Loss Change Rate Balancing[A]. 2021 IEEE winter conference on applications of computer vision (WACV)[C]. 2021: 2545-2554
- [143]Fan J., Yuan X., Miao Z., et al. Full Attention Wasserstein GAN with Gradient Normalization for Fault Diagnosis Under Imbalanced Data[J]. IEEE Transactions on Instrumentation and Measurement, 2022,71(1): 1-16
- [144]Arjovsky M., Chintala S., Bottou L. Wasserstein GAN[EB/OL]. .arXiv preprint arXiv:1701.07875, 2017
- [145]Goodfellow I., Pouget-Abadie J., Mirza M., et al. Generative Adversarial Nets[A]. Advances in neural information processing systems: Vol. 27[C]. Curran Associates, Inc., 2014: 1-9
- [146]Li Z., Liu H., Zhao J., et al. A Power System Disturbance Classification Method Robust to PMU Data Quality Issues[J]. IEEE Transactions on Industrial Informatics, 2021,18(1): 130-142
- [147]Shi Z., Yao W., Zeng L., et al. Convolutional Neural Network-Based Power System Transient Stability Assessment and Instability Mode Prediction[J]. Applied Energy, 2020,263(1): 114586
- [148]Cai H., Hill D. J. A Real-Time Continuous Monitoring System for Long-Term Voltage Stability with Sliding 3D Convolutional Neural Network[J]. International Journal of Electrical Power & Energy Systems, 2022,134(1): 107378
- [149]Zhang C., Kuppannagari S. R., Kannan R., et al. Generative Adversarial Network for Synthetic Time Series Data Generation in Smart Grids[A]. 2018 IEEE international conference on communications, control, and computing technologies for smart grids (SmartGridComm)[C]. IEEE, 2018: 1-6
- [150]Yoon J., Jordon J., van der Schaar M. GAIN: Missing Data Imputation Using Generative Adversarial Nets[A]. Dy J., Krause A. Proceedings of the 35th international conference on machine learning: Vol. 80[C]. PMLR, 2018: 5689-5698
- [151]Joshi P. M., Verma H. Synchrophasor Measurement Applications and Optimal Pmu Placement: A Review[J]. Electric Power Systems Research, 2021,199(1): 107428
- [152]Fabozzi D., Van Cutsem T. On Angle References in Long-Term Time-Domain Simulations[J]. IEEE Transactions on Power Systems, 2011,26(1): 483-484
- [153]Fan S., Ding H. Time Domain Transformation Method for Accelerating Emtp Simulation of Power System Dynamics[J]. IEEE Transactions on Power Systems, 2012,27(4): 1778-1787

- [154]Liu Y., Sun K., Yao R., et al. Power System Time Domain Simulation Using a Differential Transformation Method[J]. IEEE Transactions on Power Systems, 2019,34(5): 3739-3748
- [155]Osipov D., Sun K. Adaptive Nonlinear Model Reduction for Fast Power System Simulation[J]. IEEE Transactions on Power Systems, 2018,33(6): 6746-6754
- [156]He M., Vittal V., Zhang J. Online Dynamic Security Assessment with Missing Pmu Measurements: A Data Mining Approach[J]. IEEE Transactions on Power Systems, 2013,28(2): 1969-1977
- [157]van der Maaten L., Hinton G. Visualizing Data Using T-Sne[J]. Journal of Machine Learning Research, 2008,9(Nov): 2579-2605
- [158]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
- [159]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(05): 1776-1787
- [160]吴俊勇, 张若愚, 季佳伸, 等. 计及漏判/误判代价的两阶段电力系统暂态稳定预测方法[J]. 电力系统自动化, 2020,44(24): 44-52
- [161]李福成, 徐箭, 廖思阳, 等. 基于样本关注度和多层次特征的多阶段电力系统暂态稳定评估[J]. 中国电机工程学报, 2021,41(22): 7596-7608
- [162]Naseer M. M., Ranasinghe K., Khan S. H., et al. Intriguing Properties of Vision Transformers[J]. Advances in Neural Information Processing Systems, 2021,34(1): 23296-23308
- [163]Gregor K., LeCun Y. Emergence of Complex-Like Cells in a Temporal Product Network with Local Receptive Fields[EB/OL]. arXiv preprint arXiv:1006.0448, 2010
- [164]Shrestha B., Gokaraju R., Sachdev M. Out-of-Step Protection Using State-Plane Trajectories Analysis[J]. IEEE transactions on power delivery, 2013,28(2): 1083-1093
- [165]孙黎霞, 白景涛, 周照宇, 等. 基于双向长短期记忆网络的电力系统暂态稳定评估[J]. 电力系统自动化, 2020,44(13): 64-72
- [166]Ranftl R., Bochkovskiy A., Koltun V. Vision Transformers for Dense Prediction[A]. Proceedings of the IEEE/CVF international conference on computer vision[C]. 2021: 12179-12188
- [167]Zhu L., Hill D. J., Lu C. Hierarchical Deep Learning Machine for Power System Online Transient Stability Prediction[J]. IEEE Transactions on Power Systems, 2020,35(3): 2399-2411
- [168]Ashokbhai V. P., Dash S. K., Sanmugasundaram R., et al. Interface Network Time Protocol as Client in Embedded Based Power Protection System[A]. 2016 international conference on computation of power, energy information and

- commuincation (ICCPEIC)[C]. IEEE, 2016: 067-070
- [169]Mazhari S. M., Khorramdel B., Chung C., et al. A Simulation-Based Classification Approach for Online Prediction of Generator Dynamic Behavior Under Multiple Large Disturbances[J]. IEEE Transactions on Power Systems, 2020,36(2): 1217-1228
- [170]Novosel D., Bartok G., Henneberg G., et al. IEEE PSRC Report on Performance of Relaying During Wide-Area Stressed Conditions[J]. IEEE Transactions on Power Delivery, 2009,25(1): 3-16
- [171]Soni B. P., Saxena A., Gupta V., et al. Identification of Generator Criticality and Transient Instability by Supervising Real-Time Rotor Angle Trajectories Employing RBFNN[J]. ISA Transactions, 2018,83(1): 66-88
- [172]Siddiqui S. A., Verma K., Niazi K. R., et al. Real-Time Monitoring of Post-Fault Scenario for Determining Generator Coherency and Transient Stability Through ANN[J]. IEEE Transactions on Industry Applications, 2018,54(1): 685-692
- [173]Lecun Y., Bottou L., Bengio Y., et al. Gradient-Based Learning Applied to Document Recognition[J]. Proceedings of the IEEE, 1998,86(11): 2278-2324
- [174]Kingma D. P., Ba J. Adam: A Method for Stochastic Optimization[EB/OL]. arXiv preprint arXiv:1412.6980, 2014
- [175]Florea A.-C., Andonie R. Weighted Random Search for Hyperparameter Optimization[J]. International Journal of Computers Communications & Control, 2019,14(2): 154-169
- [176]Ren C., Xu Y., Zhang R. An Interpretable Deep Learning Method for Power System Transient Stability Assessment Via Tree Regularization[J]. IEEE Transactions on Power Systems, 2022,37(5): 3359-3369
- [177]Tan M., Le Q. V. MixConv: Mixed Depthwise Convolutional Kernels[EB/OL]. .arXiv preprint arXiv:1907.09595, 2019
- [178]Park N., Kim S. How Do Vision Transformers Work?[A]. ICLR 2022[C]. 2022: 1-26