

DOI:10.19651/j.cnki.emt.2416719

基于 SCSC-Swin Transformer 的电力系统 暂态稳定预测方法*

刘文胜¹ 荣娜¹ 李宏伟² 周洪才¹ 张异浩¹

(1. 贵州大学电气工程学院 贵阳 550025; 2. 南方电网超高压输电公司天生桥局 兴义 562400)

摘要: 现代电力系统在遭受扰动后,失稳模式呈现多样化,迫切需要准确识别不同的失稳模式,以采取相应的控制措施避免造成较大损失,因此本文提出一种基于改进 Swin Transformer 的电力系统暂态稳定评估方法。首先,通过时域仿真采集电力系统受扰后的电压幅值及相角特征构建起特征矩阵;然后,基于 Swin Transformer,本文提出一种空间跨尺度卷积注意力模块,用来替代原来的多头自注意力模块,该模块通过一系列不同卷积核大小的卷积层,能够充分提取到不同维度的有效特征,进而实现更为准确的预测结果。最后,通过在修改后的 New England 10 机 39 节点系统及 IEEE 50 机 145 节点系统中进行仿真实验,预测准确率分别达到 99.05% 和 99.00%,多摆失稳误判率为 0.35% 和 0.27%,这表明所提方法不仅能够对不同的失稳模式进行准确的预测,同时在噪声及 PMU 特征缺失情况下仍表现出优越的鲁棒性。

关键词: 暂态稳定预测;空间跨尺度卷积模块;失稳模式;Swin Transformer;数据驱动

中图分类号: TM712; TN929.5 **文献标识码:** A **国家标准学科分类代码:** 470.4057

Power system transient stability prediction method based on SCSC-Swin Transformer

Liu Wensheng¹ Rong Na¹ Li Hongwei² Zhou Hongcai¹ Zhang Yihao¹

(1. Department of Electrical Engineering, Guizhou University, Guiyang 550025, China;

2. Tianshengqiao Bureau, CSG EHV Power Transmission Company, Xingyi 562400, China)

Abstract: In modern power systems, instability modes have become increasingly diversified following disturbances, necessitating the accurate identification of various instability modes to implement appropriate control measures and prevent significant losses. Therefore, a transient stability assessment method for power systems based on an improved Swin Transformer is proposed in this paper. Firstly, time-domain simulations are conducted to collect voltage magnitude and phase angle characteristics following disturbances, which are used to construct a feature matrix. Then, building upon the Swin Transformer, a spatial cross-scale convolutional attention module is introduced to replace the original multi-head self-attention module. This new module utilizes a series of convolutional layers with different kernel sizes to effectively extract features across multiple dimensions, leading to more accurate prediction results. Finally, simulation experiments on the modified New England 10-machine 39-bus system and IEEE 50-machine 145-bus system show prediction accuracies of 99.05% and 99.00%, respectively, with multi-swing instability misjudgment rates of 0.35% and 0.27%. These results demonstrate that the proposed method not only accurately predicts different instability modes but also exhibits superior robustness in the presence of noise and missing PMU features.

Keywords: transient stability prediction; spatial cross-scale convolution module; instability modes; Swin Transformer; data-driven

0 引言

随着现代电力系统的飞快建设,可再生能源和电力电

子装置接入的比例大幅提升,电力系统的安全稳定运行面临巨大挑战^[1]。系统在遭受较大扰动时,一旦发生失稳,将会造成较大损失,如设备损坏及大规模停电事故等^[2]。暂

收稿日期:2024-08-22

* 基金项目:贵州省科技支撑计划项目([2023]290)、贵州省科技支撑计划项目([2023]329)、贵州省科学技术基金(黔科合基础-ZK[2021]一般277)、贵州省优秀青年科技人才项目(黔科合平台人才[2021]5645)资助

态稳定预测(transient stability prediction, TSP)是保障电力系统安全稳定运行的重要举措之一,在现代电力系统飞速发展的背景下,如何能够对电力系统进行可靠准确的暂态稳定评估具有重大研究意义^[3]。

传统的暂态稳定评估方法主要包括时域仿真法(间接法)^[4](time domain simulation, TDS)和直接法^[5](direct method, DM),两种方法都是从机理层面进行分析。时域仿真法和直接法都无法满足在线实时计算并做出响应的需求。随着电力系统中信息采集装置的完善,大量同步相量测量单元(phasor measurement unit, PMU)及广域测量系统(wide area measurement system, WAMS)在电力系统中得以实际应用^[6],大量专家学者开展了大量关于人工智能方法在电力系统领域的应用研究。人工智能方法主要通过训练数据为驱动工具来构造运行变量与相应安全指标间的映射关系,当把训练好的模型在线应用时,通过从 PMU 接收到的实时量测数据即可实现暂态稳定评估,此类方法不仅响应速度快,同时也能保持较高的准确性。

常见的应用于电力系统暂态稳定评估的人工智能方法主要包括两类,一类是传统的机器学习方法,包括极限学习机(extreme learning machine, ELM)^[7]、支持向量机(support vector machine, SVM)^[8]、随机森林(random forest, RF)^[9]等;另一类则是新兴的深度学习方法,包括卷积神经网络(convolutional neural network, CNN)^[10]、长短期记忆网络(long short term memory network, LSTM)^[11]、生成对抗网络等(generative adversarial networks, GAN)^[12]、深度强化学习^[13]等,这些基于数据驱动型的方法有力推动了电力系统暂态稳定预测方法的进步,为电力系统安全稳定运行提供了强有力保障。

近年来,将人工智能方法应用于暂态稳定评估领域的研究颇多,其中文献^[14]提出了一种基于 CNN 的集成暂态稳定评估方法,尽管 CNN 对于特征的提取能力非常优越,但卷积核大小的设置对于模型的性能影响较大,太大的卷积核无法充分提取局部特征,过小的卷积核对于全局特征的提取亦不充足。文献^[15]开展了基于 Transformer 的暂态稳定评估模型可解释性及模型更新方法研究,尽管 Transformer 在各种视觉任务中已经取得了较为优越的表现,但自注意力模块对于特征的提取仍不够充分,可能导致部分重要特征被忽略。

因此,针对现代电力系统失稳模式不再单一,多摆失稳频发发生的情况,本文提出一种基于改进 Swin Transformer 的暂态稳定方法,在 Swin Transformer 的基础上引入空间跨尺度卷积模块(spatial cross-scale convolutional module, SCSC),该模块通过一系列不同大小的卷积核,能够从不同维度对特征进行挖掘,从而实现更为准确的预测结果。

1 暂态稳定与失稳模式

针对不同的失稳模式所采取的控制措施不同,因此如

何准确的预测不同的失稳模式具有重要研究意义。不同失稳模式示意图如图 1 所示。




图 1 不同失稳模式的功角曲线

Fig. 1 Rotor angle curves of different instability modes

在现代电力系统中,由于大规模新能源及大量电力电子设备的接入,电力系统的失稳模式不再单一。当发电机的同步转矩不足时,导致的失稳现象往往以非周期性角度分离的形式出现,即首摆失稳,此类型失稳一般发生于故障后 3~5 s;当发电机的阻尼转矩出现不足时,往往会发生震荡失稳,发电机的振幅会大幅增加,一般发生于故障后 10~20 s。

2 基于 SCSC-Swin Transformer 的 TSP 预测模型

2.1 输入特征构建

初始特征的构建对 TSP 结果的准确性有至关重要的作用。由文献^[16]所得结论,本文选取故障切除后一段时间的每台发电机节点的电压幅值和相角作为第一阶段 TSP 模型的初始特征。第二阶段则将故障切除后一段时间的发发电机功角轨迹作为初始特征。因为神经网络只能处理实数数据,因此将电压向量分离为幅值和相角两部分并将其拼接在一个矩阵中作为模型的输入:

$$\begin{bmatrix} V_{11} & V_{12} & \cdots & V_{1r} & \Phi_{11} & \Phi_{12} & \cdots & \Phi_{1r} \\ V_{21} & V_{22} & \cdots & V_{2r} & \Phi_{21} & \Phi_{22} & \cdots & \Phi_{2r} \\ \cdots & \cdots & \cdots & \cdots & \cdots & \cdots & \cdots & \cdots \\ V_{G1} & V_{G2} & \cdots & V_{Gr} & \Phi_{G1} & \Phi_{G2} & \cdots & \Phi_{Gr} \end{bmatrix} \quad (1)$$

其中, G 表示发电机的标号, t 表示采样个数。

2.2 空间跨尺度卷积模块

该模块主要包括通道缩减、空间跨尺度编码器、空间维度组合和通道恢复 4 个部分。假设第 k 层的输入可以表示为 $X_k \in R^{N \times C \times H \times W}$, 其中 N 、 C 、 H 、 W 分别为特征图的 Batchsize、通道数、高度及宽度。图 2 为所提出的空间跨尺度卷积模块,在通道缩减过程中,映射函数为式(2)所示的 1×1 卷积运算:

$$X_d^k = W_d^k * X^k \quad (2)$$

式中: $*$ 表示卷积操作, $X_d^k \in R^{N \times C/m \times H \times W}$, 其中 m 为空间跨尺度编码器中不同尺寸卷积核的数量。

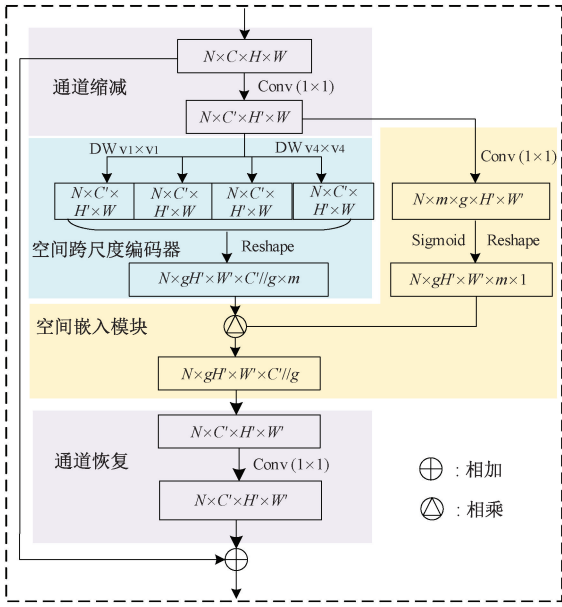


图 2 SCSC 模块
Fig. 2 SCSC module

对于空间跨尺度编码器模块,计算过程主要如式(3)和式(4)所示。

$$X_s^k = \{X_{s1}^k, X_{s2}^k, \dots, X_{si}^k, \dots, X_{sm}^k\} \quad (3)$$

$$X_{si}^k = W_{si}^k * X_d^k, W_{si}^k \in R^{C // m \times H' \times W'} \quad (4)$$

在获取到不同维度的空间特征后,该模块通过一个空间嵌入模块对每个空间位置提取到的跨尺度特征进行动态融合。

$$M^k = SEM(X_d^k) \quad (5)$$

在空间嵌入模块中,首先通过 \$1 \times 1\$ 的卷积运算将通道数减少到 \$m \times g\$, 然后通过 sigmoid 运算得到结果 \$M^k \in R^{N \times m \times g \times H' \times W'}\$, 其中 \$g\$ 为组合次数,能够实现更多的动态组合。然后将 \$X_s^k\$ 的大小重塑为 \$N \times g \times H' \times W' \times C // m // g \times m\$, 将 \$M^k\$ 的大小重塑为 \$N \times g \times H' \times W' \times m \times 1\$, 即可得到嵌入模块输出的特征图:

$$X_e^k = Matmul(X_s^k, M^k) \quad (6)$$

式中: \$X_e^k \in R^{N \times C // m \times H' \times W'}\$。

最后,将所得到的特征图进行通道恢复操作:

$$X_o^k = W_r^k * X_e^k \quad (7)$$

式中: \$X_o^k \in R^{N \times C \times H' \times W'}\$。整个过程中所有运算皆可微,最终可以得到目标函数为:

$$W_d^k, W_s^k, \min_{M^k}, W_T^k |_{k=1}^K \frac{1}{n} \sum_{i=1}^n L(Y_i; \hat{Y} | X_i) \quad (8)$$

式中: \$W\$ 为学习权重, \$(X_i, Y_i), i \in [1, n]\$ 为输入到模型的特征图及其标签, \$L\$ 为损失函数。

2.3 基于 SCSC-Swin transformer 的暂稳评估模型

Swin Transformer 模型通过分层的结构设计、Patch Embedding、Shifted Window 操作以及自注意力机制等手

段,使模型具有良好性能和可扩展性,适用于各种视觉任务,如图像分类、目标检测、语义分割等,从而实现了图像的深度理解和表示。整个模型被划分 4 个阶段,每个阶段由如图 3 所示的两个连续的 Swin Transformer 模块组成。这样的设计能够像 CNN 一样逐层扩大感受野,从而有利于捕捉图像局部信息和全局信息。




图 3 两个连续的 Swin Transformer 块
Fig. 3 Two successive Swin Transformer blocks

Swin Transformer 模型通过实用滑动窗口的注意力机制取代掉原始的多头自注意力机制 (multi-head attention, MSA), 而其他网络层保持不变。如图 3 所示, Swin Transformer 主要由一个基于滑动窗口的 MSA 模块和一个两层的多层感知机 (multi layer perceptron, MLP) 组成。在每个 MSA 和 MLP 模块之前,还有一个正则化层,模块之后通过残差链接。

Swin Transformer 采用多头自注意力模块,该模块的结构图如图 4 所示,每个头有独立的权重矩阵和 \$Q, K, V\$ 矩阵。




图 4 MSA 结构图

Fig. 4 The structure diagram of MSA

在原始的 Swin Transformer 中,尽管已经在很多视觉任务中取得了非常优越的表现,但仍存在一些不足,大的卷积核和自注意力机制对于特征的提取不够充分。因此,在本文所提的模型中,其中该模型结构图如图 5 所示,通过引

入空间跨尺度卷积模块,该模块通过一系列的接受域能够学习到更有效的特征,从而能够实现更为准确的预测结果。

当通过从电力系统中采集到的数据构建起特征变量并输入到模型中进行训练后,所提的 SCSC 模块首先对输入特征的尺寸进行缩减,然后将缩减后的特征输入到空间跨尺度

编码器中,该编码器由一系列不同尺寸卷积核的深度卷积操作组成,能够有效的降低计算资源的消耗,不同大小的卷积运算能提取到不同维度的特征。最后,不同接受域下所提取到的特征通过一个空间嵌入模块进行融合,从而实现对特征的最终提取,为最终的预测结果提供充分依据。

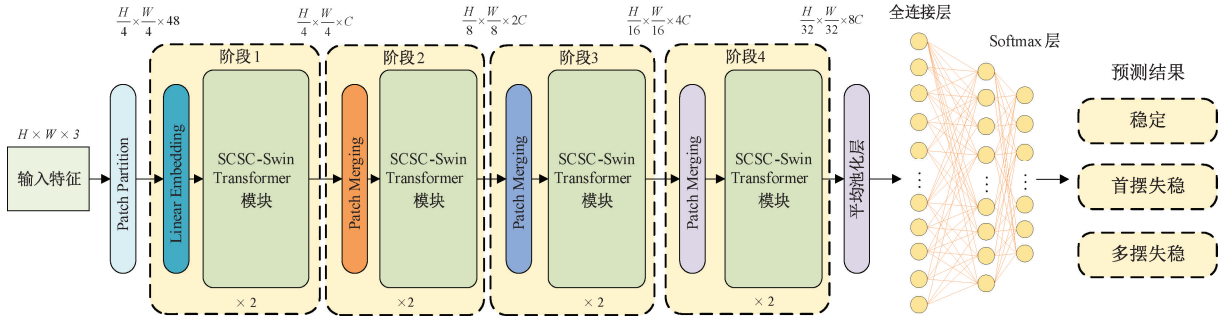


图 5 所提的 SCSC-Swin Transformer 结构

Fig. 5 The structure diagram of the proposed SCSC-Swin Transformer

2.4 所提方法的评估流程

本文所提出的基于 SCSC-Swin Transformer 的暂态稳定评估方法主要包括数据集构建、离线训练和在线评估 3 个阶段。具体的实施流程如图 6 所示。

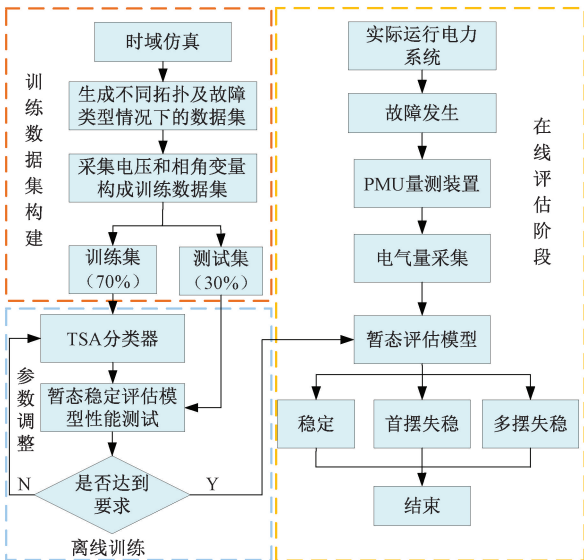


图 6 所提方法流程图

Fig. 6 Flowchart of the proposed method

1) 训练数据集构建:通过时域仿真,设置不同的故障类型、故障位置及不同运行拓扑等情况,然后采集电压和相角变量构建起训练数据集,作为所提模型的输入训练特征。

2) 离线训练:模型通过训练后,即可构建起每个样本与对应标签之间的映射关系,从而可以用于后续的实际电力系统在线预测。

3) 在线评估:训练好的分类器即可投入应用,根据电力系统中 PMU 装置及广域测量系统实时采集到的电气信息即可进行实时预测,然后为电力系统的安全稳定运行提

供充分保障。

2.5 评价指标

本文通过混淆矩阵来构建起暂态稳定评估模型的评估指标,其中混淆矩阵的定义如表 1 所示。

表 1 混淆矩阵

Table 1 Confusion matrix

真实标签	预测标签			总计
	稳定	首摆失稳	多摆失稳	
稳定	T_{SS}	F_{SA}	F_{SD}	N_S
首摆失稳	F_{AS}	T_{AA}	F_{AD}	N_A
多摆失稳	F_{DS}	F_{DA}	T_{DD}	N_D

本文通过准确率和多摆失稳误判率来对模型的性能进行评判,两个指标的定义分别如下:

$$ACC = \frac{T_{SS} + T_{AA} + T_{DD}}{N_S + N_A + N_D} \quad (9)$$

$$DMR = \frac{F_{DS} + F_{DA}}{N_S + N_A + N_D} \quad (10)$$

式中: $N_S = T_{SS} + F_{SA} + F_{SD}$,为测试样本中稳定样本的总数量; $N_A = F_{AS} + F_{AD} + T_{AA}$,为测试样本中首摆稳定样本的总数; $N_D = F_{DS} + F_{DA} + T_{DD}$,为测试样本中多摆稳定样本的总数。

3 案例研究

3.1 数据生成

为了验证本文所提方法的有效性,本文基于修改后的 IEEE10 机 39 节点系统及 IEEE50 机 145 节点系统中验证所提方法的有效性。在 IEEE10 机 39 节点系统中,3 个风电厂分别接于 22、29 和 39 节点处,整个系统所承载的总负荷为 5 856 MW。在保证发电机出力使潮流收敛的情况

下,本文考虑了风力发电量渗透率分别为 10%,20%,...,50%情况下的 5 种情况,并考虑了负荷水平分别为 85%~120%之间以 5%的步长下的共计 9 种负荷水平。故障设置方面,本文在无变压器的 34 条线路上设置最为严重的三相短路故障。故障持续时间为 0.02~0.2 s,变化步长为 0.02 s,故障发生于 0.1 s 处,总仿真时长 6 s。本文借助 Matlab 和 PSS/E34 软件开展时域仿真,在 10 机系统中共计获取样本 13 277 个,其中稳定样本 8 270 个,首摆失稳样本 3 682 个,多摆失稳样本 1 325 个;在 50 机系统中共生成样本 28 635 个,其中稳定样本 17 201 个,首摆失稳样本 8 156 个,多摆失稳样本 3 278 个。最后将数据集进行随机打乱并划分为训练集和测试集,其中数据集的 70%用作训练集,剩下的 30%用作测试集。

在模型的训练过程中,超参数的设置如下:初始学习率为 0.005,Epochs 为 100 次,每经过 20 次训练,学习率乘以 0.5,每个 Epoch 均重新随机打乱样本,MiniBatchSize 为 256,优化求解器为 Adam。

对于每个通过时域仿真生成的样本,通过暂态稳定指数进行判断是否稳定,在本文中,0 为稳定样本,1 为首摆失稳样本,2 为多摆失稳样本。

$$TSI = \frac{360^\circ - |\Delta\delta_{\max}|}{360^\circ + |\Delta\delta_{\max}|} \quad (11)$$

式中: $|\Delta\delta_{\max}|$ 为不同机组间任意两台发电机功角差的最大值。当 TSI 值 >0 时,系统处于稳定状态;反之,系统则处于失稳状态。修改后的新英格兰 10 机系统如图 7 所示。

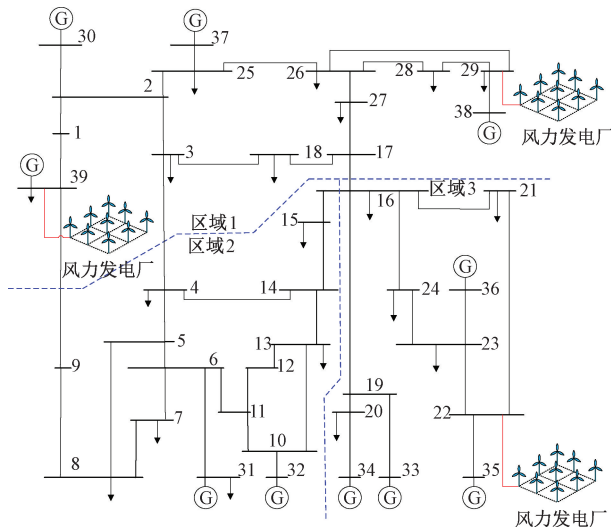


图 7 修改后的新英格兰 10 机系统

Fig. 7 The modified New England 10-machine system

3.2 特征观察窗口选择

当电力系统遭受较大扰动时,大规模的暂态能量会在电力系统中聚集起来,从而会导致电力系统的快速失稳。若不能迅速对电力系统失稳模式进行准确的识别,则会使整个电力系统受到扰动,导致大规模停电事故的发生,对

电力系统造成巨大损失。

从图 8 和 9 不难看出,当电力系统遭受到较大扰动后,较短时间内会引起失稳情况,其中最早的失稳发生于故障后 0.76 s,属于较为严重的工况。利用传统方的暂态稳定预测方法较难实时准确预测,因此本文采用基于人工智能的方法进行预测,考虑到电力系统中 PMU 装置自身的延迟约为 0.1 s,本文选用故障后 0.3 s 内时间窗口的电气特征量作为模型的输入训练特征,从而及时为运行人员提供可靠的动作信号及依据。




图 8 严重故障的首摆失稳时刻

Fig. 8 The first swing instability moments of severe faults




图 9 严重故障的多摆失稳时刻

Fig. 9 The multiple swing instability moments of severe faults

3.3 模型有效性验证

为了验证所提出的暂态稳定预测模型的有效性,本文基于 10 机以及 50 机系统进行时域仿真生成训练数据集,通过不同的分类器进行测试,具体的测试结果如下。

如表 2 中结果所示,其中 Swin T 为未经改进过的 Swin Transformer,在包括 LSTM、GRU、CNN 在内的不同分类器中,本文所提出的基于 SCSC-Swin Transformer 的暂态稳定评估模型准确率达到了 99.05%,较 GRU、LSTM、CNN、RF、Swin T 分别高出了 0.46%、0.51%、0.26%、0.33%,在所有分类器中表现最佳。此外,该模型的多摆误判率在所有分类器中也最低,仅为 0.35%,RF 的多摆误判率最高,达到了 1.31%,较本文所提模型高出

了 0.96%。

表 2 10 机系统不同分类器预测表现

Table 2 Performance of different classifiers on 10-machine system

分类器	ACC/%	DMR/%
GRU	98.59	1.13
LSTM	98.54	0.95
CNN	98.79	0.70
RF	98.14	1.31
Swin T	98.72	0.58
SCSC-Swin T	99.05	0.35

图 10 为所提暂态稳定评估模型在 10 机系统中的预测结果混淆矩阵,其中对角元素分别为各个类别样本中被正确预测的数量,空白处元素则对应每个类别中被误判为其他类样本的数量。不难看出,部分失稳样本会被误判为稳定样本,这需要特别重视,因为失稳样本被误判为稳定样本时,电力系统不会采取任何安全措施,可能会对电力系统造成巨大损失,但从混淆矩阵中可以看到,该模型将失稳样本误判为稳定样本的数量很少,表明模型的性能较为优越。




图 10 10 机系统预测混淆矩阵

Fig. 10 The confusion matrix of 10-machine system

图 11 和 12 为通过 t-SNE 对 10 机系统进行可视化的结果,其中图 11 为对输入到模型中的原始训练数据可视化结果,图 12 为模型最后一层的输出结果,可以看到经过该分类器进行特征提取后,各类样本间的边界更为清晰,这表明模型具有很好的特征提取能力,能够充分挖掘到各类样本的有效特征,从而实现更准确的预测结果。

表 3 中为不同分类器在 50 机系统中的测试结果,不难看出在不同的分类器中,SCSC-Swin T 取得了最高的准确率,其值为 99.00%,较其他分类器亦为更佳,与未引入 SCSC 模块的 Swin T 相比,SCSC-Swin T 的准确率高出了 0.18%,这表明引入 SCSC 模块替代 MSA 后,能够实现更充分的特征提取,有效降低模型误判的可能性。




图 11 原始数据分布

Fig. 11 Distribution of raw data

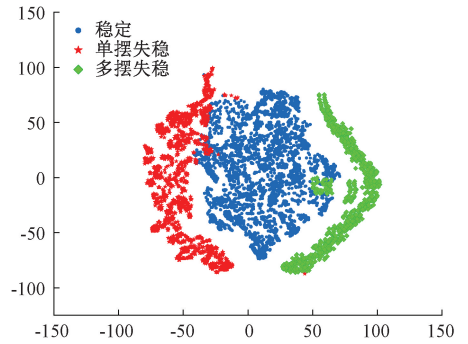


图 12 最后一层输出

Fig. 12 Output of the last layer

表 3 50 机系统中不同分类器表现

Table 3 Performance of different classifiers on 50-machine system

分类器	ACC/%	DMR/%
LSTM	98.54	0.76
GRU	98.61	0.68
CNN	98.74	0.51
RF	97.68	1.54
Swin T	98.82	0.41
SCSC-Swin T	99.00	0.27

在所有的分类器中,本文所提的暂态稳定评估模型也取得了最低的多摆误判率,其值为 0.27%,表明模型能够有效降低失稳样本被误判为稳定样本的数量,能够有效减少对电力系统造成的损失。

图 13 为在 50 机系统中该模型的样本预测情况,可以看到在系统规模扩大后,该模型仍能够保持着较好的表现。因此,当电力系统中发生暂态失稳时,该模型能够有效的进行预警,从而提供可靠的依据。

图 14 和 15 为 50 机系统中通过 t-SNE 对训练样本进行可视化后所得结果,其中图 14 为原始数据可视化结果,图 15 为经过模型提取后的各类样本特征可视化结果。可以清楚的看到,经过模型特征提取后,各类样本间的分类




图 13 50 机系统预测混淆矩阵

Fig. 13 The confusion matrix of 50-machine system

边界较为清晰,能够清楚的把各类样本的特征提取到,进而做出准确的预测。




图 14 原始数据分布

Fig. 14 Distribution of raw data




图 15 最后一层输出

Fig. 15 Output of the last layer

通过前面的分析不难看出,所提模型在引入 SCSC 模块后,不仅在众多分类器中均为表现最佳,且能有效减少失稳样本被误判为稳定样本的数量,从而避免使电力系统遭受巨大损失。同时,对于各类样本的特征能够实现充分提取,从而为运行控制人员提供可靠依据。

3.4 模型鲁棒性测试

考虑到实际的电力系统在运行过程中难免会遭受噪声的影响,需要模型具有较好的鲁棒性。因此,为了测试本文所提模型的抗噪性能,基于 10 机系统以及 50 机系统,分别在训练数据集中分别加入了包括 45、35、25 以及

15 dB 在内的 4 种不同信噪比的高斯白噪声进行测试,具体的测试结果如表 4 所示。

表 4 不同分类器预测表现

Table 4 Performance of different classifiers

评价指标	分类器	45 dB	35 dB	25 dB	15 dB
ACC/%	LSTM	98.44	98.24	97.94	97.46
	GRU	98.52	98.39	98.16	97.84
	CNN	98.76	98.54	98.37	98.11
	RF	98.04	97.89	97.66	97.36
	Swin T	98.77	98.62	98.44	98.16
	SCSC-Swin T	98.92	98.72	98.54	98.37
DMR/%	LSTM	1.21	1.38	1.61	1.81
	GRU	1.08	1.23	1.38	1.56
	CNN	0.75	0.88	1.05	1.26
	RF	1.41	1.56	1.73	2.01
	Swin T	0.65	0.78	0.95	1.13
	SCSC-Swin T	0.45	0.58	0.80	1.03

表 4 为 10 机系统中不同分类器在加入不同信噪比噪声后的预测表现。在数据集中加入噪声后,各模型的预测性能都出现了一定程度的下降,但本文所提模型仍保持着最好的表现,在最为严重的信噪比 15dB 情况下,多摆失稳误判率为 1.03%,准确率仍达到了 98.37%,在所有模型中表现最佳。且准确率相较于 LSTM、GRU、CNN、RF、Swin T 分别高出了 0.91%、0.53%、0.26%、1.01%、0.21%,这充分表明本文所提模型具有较好的鲁棒性,能够在噪声环境中进行应用。

表 5 则为在 50 机系统中的测试结果。ACC 为不同分类器在 4 种信噪比噪声影响下的预测准确率,可以看到随着噪声强度的增强,各模型的准确率均出现了一定程度的

表 5 不同分类器预测表现

Table 5 Performance of different classifiers

评价指标	分类器	45 dB	35 dB	25 dB	15 dB
ACC/%	LSTM	98.49	98.31	97.96	97.76
	GRU	98.51	98.37	98.09	97.93
	CNN	98.66	98.54	98.37	98.11
	RF	97.92	97.73	97.59	97.23
	Swin T	98.72	98.58	98.31	98.16
	SCSC-Swin T	98.93	98.78	98.46	98.31
DMR/%	LSTM	0.91	1.08	1.37	1.69
	GRU	0.80	0.92	1.11	1.39
	CNN	0.56	0.71	0.92	1.13
	RF	1.28	1.42	1.66	1.93
	Swin T	0.56	0.69	0.83	1.11
	SCSC-Swin T	0.37	0.48	0.76	1.04

下降,其中在 15 dB 时,RF 的准确率更是下降到了 97.23%,说明该模型的鲁棒性较差。相比之下,本文所提模型在 15 dB 噪声影响下,仍然达到了 98.31% 的预测准确率,模型的有效性得到验证。DMR 值为 50 机系统中不同分类器的多摆误判率结果,本文所提模型的多摆失稳误判率在所有模型中均为最低,在信噪比为 15 dB 时,多摆失稳误判率为 1.04%,而 RF 模型达到了 1.93%,这表明所提模型相较各模型性能更佳。

3.5 PMU 缺失实验

在实际的电力系统中,难免 PMU 装置会发生故障,导致信息采集不全,这可能会导致模型的性能出现下降,因此,需要考虑 PMU 故障导致的特征缺失对模型性能所造成的影响。本文基于 10 机及 50 机两个系统,随机设置母线 PMU 装置故障情况,分别构建了 N-1、N-2 及 N-3 数据集,具体的测试结果如表 6 和表 7 所示。

表 6 10 机系统 PMU 缺失测试

Table 6 PMU missing tests on 10-machine system

缺失母线	ACC/%	DMR/%
母线 5	98.87	0.55
母线 17	98.77	0.68
母线 24	98.92	0.48
母线 5 和 17	98.79	0.63
母线 5 和 24	98.82	0.60
母线 17 和 24	98.72	0.73
母线 5、7 和 24	98.64	0.88

表 7 50 机系统 PMU 缺失测试

Table 7 PMU missing tests on 50-machine system

缺失母线	ACC/%	DMR/%
母线 7	98.91	0.41
母线 53	98.80	0.52
母线 139	98.89	0.49
母线 7 和 53	98.73	0.72
母线 7 和 139	98.75	0.59
母线 53 和 139	98.71	0.64
母线 7、53 和 139	98.66	0.91

根据表 6 和表 7 中的结果可见,随着 PMU 缺失数量的增加,模型的预测性能会逐步的出现下降,但表现仍可接受。在 10 机系统中,缺失 5、7 和 24 三条母线的特征信息时,所达到的预测准确率为最低,为 98.64%,比特征信息完整时仅低了 0.23%,这说明模型的鲁棒性较为优越,在系统的信息缺失情况下仍具有较好表现;随着系统规模扩大,在 50 机系统中,即使在缺失三条母线特征信息的情况下,模型仍取得了 98.66% 的预测准确率,这表明文中所提出的模型对 PMU 缺失具有较好的鲁棒性,能够适用于

较复杂的电力系统运行场景。

4 结 论

针对现代电力系统失稳模式不再单一,多摆失稳频频发生的问题,本文提出一种基于 SCSC-Swin Transformer 的暂态稳定预测方法,并在 10 机系统和 50 机系统进行了仿真实验,结果表明所提方法在引入空间跨尺度卷积模块后,能够对不同失稳类别对应的样本实现更为充分的特征提取,可视化所得结果中各类别样本间的特征边界更为清晰,这表明该模块能够有效提升模型的特征提取能力。从而能够更为准确的对不同的失稳模式进行预测,且在噪声环境下仍保持着较为优越的表现,抗噪性能较好,能够为电力系统的运行控制提供保障。

但基于人工智能的预测方法其本身就是一个黑箱模型,如何能够有效提升模型预测结果的可信度值得研究。在未来的研究中,将对模型的可解释性开展研究,以期能够使模型的决策过程更加透明化。

参考文献

- [1] 曾进辉,苏旨音,肖锋,等.基于经验模态分解和 ISSA-LSTM 的短期电力负荷预测[J/OL]. 电子测量技术, 1-7[2024-07-14]. <http://kns.cnki.net/kcms/detail/11.2175.TN.20241018.1837.033.html>. ZENG J H, SU ZH Y, XIAO F, et al. Short-term power load forecasting based on empirical modal decomposition and ISSA-LSTM [J/OL]. Electronic Measurement Technology, 1-7 [2024-07-14]. <http://kns.cnki.net/kcms/detail/11.2175.TN.20241018.1837.033.html>.
- [2] 胡源,薛松,张寒,等.近 30 年全球大停电事故发生的深层次原因分析及启示[J]. 中国电力,2021,54(10):204-210. HU Y, XUE S, ZHANG H, et al. Cause analysis and enlightenment of global blackouts in the past 30 years[J]. Electric Power, 2021, 54(10): 204-210.
- [3] 尹雪燕,闫炯程,刘玉田,等.基于深度学习的暂态稳定评估与严重程度分级[J]. 电力自动化设备,2018,38(5): 64-69. YIN X Y, YAN J CH, LIU Y T, et al. Deep learning based transient stability assessment and severity grading[J]. Electric Power Automatic Equipment, 2018, 38(5): 64-69.
- [4] 李永康,刘宝柱,胡俊杰.基于数据驱动与时域仿真融合的电力系统暂态稳定快速评估[J]. 电网技术, 2023,47(11):4386-4396. LI Y K, LIU B ZH, HU J J. Fast transient stability assessment of power systems based on the integration of data-driven and time-domain simulation approaches[J]. Power System Technology, 2023,47(11):4386-4396.

- [5] 贾天下,孙华东,赵兵,等.基于结构保持能量函数的电力系统暂态稳定分析方法研究[J].中国电机工程学报,2020,40(9):2819-2826.
JIA T X, SUN H D, ZHAO B, et al. Research on transient stability analysis method of power system based on network structure preserving energy function [J]. Proceedings of the CSEE, 2020, 40(9): 2819-2826.
- [6] 杨挺,赵黎媛,王成山.人工智能在电力系统及综合能源系统中的应用综述[J].电力系统自动化,2019,43(1):2-14.
YANG T, ZHAO L Y, WANG CH SH. Review on application of artificial intelligence in power systems and integrated energy systems [J]. Automation of Electric Power Systems, 2019, 43(1): 2-14.
- [7] 葛琼宇,王致杰.基于 ISSA-ELM 的短期电力负荷预测研究[J].国外电子测量技术,2022,41(4):119-125.
GE Q Y, WANG ZH J. Research on short-term load forecasting in smart grid based on ISSA-ELM [J]. Foreign Electronic Measurement Technology, 2022, 41(4): 119-125.
- [8] 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.
DAI Y H, CHEN L, ZHANG W L, et al. Power system transient stability assessment based on comprehensive SVM classification model and key sample set [J]. Proceedings of the CSEE, 2016, 36(5): 1173-1180.
- [9] 武宇翔,韩肖清,牛哲文,等.基于变权重随机森林的暂态稳定评估方法及其可解释性分析[J].电力系统自动化,2023,47(14):93-104.
WU Y X, HAN X Q, NIU ZH W, et al. Transient stability assessment method based on variable weight random forest and its interpretability analysis [J]. Automation of Electric Power Systems, 2023, 47(14): 93-104.
- [10] 闫宇楠,刘智康,徐佳文,等.基于 CBAM-CNN 和压电悬臂梁的温度解耦质量感知方法[J].仪器仪表学报,2024,45(4):113-126.
YAN Y N, LIU ZH K, XU J W, et al. Temperature decoupled mass sensing based on CBAM-CNN and piezoelectric cantilever beam [J]. Chinese Journal of Scientific Instrument, 2024, 45(4): 113-126.
- [11] 朱振宇,高德欣.基于 CNN-BiLSTM 网络的锂离子电池健康状态检测方法[J].电子测量技术,2023,46(3):128-133.
ZHU ZH Y, GAO D X. Lithium-ion batteries state of health detection method based on CNN-BiLSTM network [J]. Electronic Measurement Technology, 2023, 46(3): 128-133.
- [12] 邵振国,张承圣,陈飞雄,等.生成对抗网络及其在电力系统中的应用综述[J].中国电机工程学报,2023,43(3):987-1004.
SHAO ZH G, ZHANG CH SH, CHEN F X, et al. A review on generative adversarial networks for power system applications [J]. Proceedings of the CSEE, 2023, 43(3): 987-1004.
- [13] 牛哲文,冀岳,李柏培,等.基于优势函数分解多智能体深度强化学习的电力系统暂态稳定预防控制方法[J/OL].电网技术,1-13[2024-07-14].<https://doi.org/10.13335/j.1000-3673.pst.2024.0389>.
NIU ZH W, JI Y, LI B Y, et al. Preventive control method of power system transient stability based on multi-agent deep reinforcement learning with advantage decomposition [J/OL]. Power System Technology, 1-13 [2024-07-14]. <https://doi.org/10.13335/j.1000-3673.pst.2024.0389>.
- [14] ZHOU Y ZH, GUO Q L, SUN H B, et al. A novel data-driven approach for transient stability prediction of power systems considering the operational variability [J]. International Journal of Electrical Power & Energy Systems, 2019, 107: 379-394.
- [15] 高发骏,王怀远,党然.基于 Transformer 的暂态稳定评估模型的可解释性分析与模型更新研究[J].电力系统保护与控制,2023,51(17):15-25.
GAO F J, WANG H Y, DANG R. Interpretability analysis and model update research of transient stability assessment model based on Transformer [J]. Power System Protection and Control, 2023, 51(17): 15-25.
- [16] SHI ZH T, YAO W, ZENG L K, et al. Convolutional neural network-based power system transient stability assessment and instability mode prediction [J]. Applied Energy, 2020, 263: 114586.

作者简介

刘文胜,硕士研究生,主要研究方向为人工智能及大数据在电力系统暂态稳定预测与控制的应用。

E-mail:gs.wslu22@gzu.edu.cn

荣娜(通信作者),讲师,硕士生导师,主要研究方向为综合能源、电力电子装备与系统。

E-mail:3466164911@qq.com