

# 控制与决策

Control and Decision

采用多层次特征融合SPP-net的暂态稳定多任务预测

陈庆超, 韩松, 毛钧毅

引用本文:

陈庆超, 韩松, 毛钧毅. 采用多层次特征融合SPP-net的暂态稳定多任务预测[J]. *控制与决策*, 2022, 37(5): 1279–1288.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2020.1568>

---

## 您可能感兴趣的其他文章

### Articles you may be interested in

[基于双分支特征融合的场景文本检测方法](#)

A scene text detection based on dual-path feature fusion

*控制与决策*. 2021, 36(9): 2179–2186 <https://doi.org/10.13195/j.kzyjc.2020.0002>

[基于神经网络的电力系统暂态稳定分布式自适应控制](#)

Neural network-based distributed adaptive control for power system transient stability

*控制与决策*. 2021, 36(6): 1407–1414 <https://doi.org/10.13195/j.kzyjc.2019.1168>

[基于多尺度特征表示的行人再识别](#)

Multi-scale feature representation for person re-identification

*控制与决策*. 2021, 36(12): 3015–3022 <https://doi.org/10.13195/j.kzyjc.2020.0952>

[一种基于多层语义特征的图像理解方法](#)

An image understanding method based on multi-level semantic features

*控制与决策*. 2021, 36(12): 2881–2890 <https://doi.org/10.13195/j.kzyjc.2020.0927>

[基于卷积长短时记忆神经网络的城市轨道交通短时客流预测](#)

Metro short-term traffic flow prediction with ConvLSTM

*控制与决策*. 2021, 36(11): 2760–2770 <https://doi.org/10.13195/j.kzyjc.2020.0501>

# 采用多层次特征融合 SPP-net 的暂态稳定多任务预测

陈庆超, 韩松<sup>†</sup>, 毛钧毅

(贵州大学 电气工程学院, 贵阳 550025)

**摘要:** 为提升基于卷积神经网络 (CNN) 的电力系统暂态稳定预测性能并呈现更全面的预测结果, 提出一种基于多层次特征融合空间金字塔池化网络 (MSPP-net) 的暂态稳定多任务预测方法. 首先, 通过同步相量测量装置 (PMUs) 获取故障清除后各发电机功角、机端母线电压幅值及相角数据, 构造出一个三维输入矩阵; 其次, 在 CNN 的基础上采用空间金字塔池化层提取高层特征的多尺度信息, 通过跳跃链接获取不同卷积层多层次特征信息, 并进行特征融合; 最后, 通过硬参数共享机制建立 MSPP-net 多任务学习模型, 以实现暂态稳定性判断、临界发电机识别和稳定裕度预测. 在 IEEE 10 机 39 母线系统、IEEE 50 机 145 母线系统和中国某省简化系统上进行仿真验证. 与传统浅层及深度学习方法相比, 结果验证了所提方法的有效性和更优的预测性能, 以及该方法在噪声环境或 PMUs 非 100% 覆盖条件下的适用性.

**关键词:** 多层次特征融合; 空间金字塔池化网络; 暂态稳定预测; 多任务预测; 卷积神经网络

中图分类号: TP273

文献标志码: A

DOI: 10.13195/j.kzyjc.2020.1568

开放科学(资源服务)标识码(OSID):



**引用格式:** 陈庆超, 韩松, 毛钧毅. 采用多层次特征融合 SPP-net 的暂态稳定多任务预测 [J]. 控制与决策, 2022, 37(5): 1279-1288.

## Multi-task prediction for transient stability using, multi-level feature fusion based SPP-net

CHEN Qing-chao, HAN Song<sup>†</sup>, MAO Jun-yi

(The Electrical Engineering College, Guizhou University, Guiyang 550025, China)

**Abstract:** In order to improve the performance of transient stability predictions based on convolutional neural networks (CNNs) and demonstrate multi-angle auxiliary decision-making information, such as transient stability classification and margin, etc., this paper proposes a multi-task model for transient stability prediction using the multi-level feature fusion based spatial pyramid pooling convolutional network. Firstly, the short-time disturbed trajectories of each generator can be obtained by phasor measurement units (PMUs), and a three-dimension information matrix may be constructed using these trajectories. Then, the spatial pyramid pooling layer and multi-level pooling layer can be employed for extracting and fusing multi-scale and multi-level feature based on the CNN. Finally, the MSPP-net is built by hard parameter sharing, so as to achieve transient stability classification, critical generators identification and stability margin prediction. The case studies have been carried on an IEEE 39-bus system, an IEEE 145-bus system and a certain provincial power grid. The results in comparison with those results from the conventional methods show that the proposed methodology is valid, and it shows the applicability when the information of PUMs is incomplete or contains noise.

**Keywords:** multi-level feature fusion; spatial pyramidal pooling network; transient stability prediction; multi-task prediction; convolutional neural networks

## 0 引言

随着同步相量测量装置 (phasor measurement units, PMUs) 的广泛应用, 5G 等信息通信技术以及深度学习等人工智能技术的快速演进, 面向高比例新

能源接入和高度电力电子化电力系统的安全稳定评估<sup>[1-2]</sup>, 特别是暂态稳定预测问题 (transient stability prediction, TSP), 从数据驱动角度出发, 借助大数据与人工智能 (artificial intelligence, AI) 技术<sup>[3]</sup> 开展电网

收稿日期: 2020-11-13; 录用日期: 2021-03-29.

基金项目: 国家自然科学基金项目 (51567006); 贵州省普通高等高校科技拔尖人才支持计划项目 (2018036); 贵州省科学技术基金项目 (黔科合基础 [2019]1100); 贵州省科技创新人才团队项目 ([2018]5615).

责任编辑: 孙秋野.

<sup>†</sup>通讯作者. E-mail: shan@gzu.edu.cn.

量测系统采集数据的特征提取和行为预测,或为新一代电力系统安全分析和控制带来新的解决方案和技术路径<sup>[3-4]</sup>.

近年来,深度学习技术底层构件的卷积神经网络(convolutional neural network, CNN)因具有优越的特征提取和建模能力,已在包括电气工程领域在内的诸多领域中广泛应用.一方面,从基于CNN的TSP方法研究进展角度来看,文献[5]通过构造受扰程度信息矩阵作为CNN输入特征,有效提高了模型预测精度.进一步地,文献[6-7]建立了CNN综合模型,对多个模型输出结果进行综合判断,提高了稳定性分类的准确性.不同于暂态稳定与否的判别,文献[8]将扰动数据转换为二维图像作为输入,利用分治策略提出了一种基于层次CNN的稳定裕度预测模型,并验证了该方法的有效性.然而,上述文献构建的TSP模型主要以稳定性或稳定裕度作为单一输出,而目前对多任务TSP研究的文献较少,如文献[9]通过建立分类和回归的CNN模型,先后对稳定性和稳定裕度进行预测,其流程较为繁琐.而文献[10]构建了CNN多输出模型,通过多任务学习(multi-task learning, MTL)<sup>[11]</sup>机制实现了暂态稳定性分类与临界发电机(critical generators, CGs)的识别,但其预测精度较低.另一方面,就CNN在计算机视觉的研究发展角度而言,文献[12]提出了一种空间金字塔池化网络(spatial pyramid pooling convolutional network, SPP-net),其能够将局部特征映射到不同维度空间并将其融合,进而有效地提取多尺度特征信息,提高了CNN分类性能<sup>[13-14]</sup>.此外,文献[15]利用不同尺寸的全局池化获取多尺度上下文信息,显著提高了目标识别的准确性.可见,多层次、多尺度特征融合已逐渐成为一种提高CNN性能的有效方法<sup>[16-17]</sup>.针对电网量测数据的复杂性、波动性及耦合性,结合多尺度、多层次特征融合方法或为提高TSP精度带来一种新的契机.

综上所述,为提高基于CNN的TSP准确度,并同时呈现多方面、多角度的分析结果,本文提出一种采用多层次特征融合空间金字塔池化网络的暂态稳定多任务预测方法(multi-level feature fusion based SPP-net, MSPP-net).借助Matlab 3.0软件,通过IEEE 10机39母线系统、一个IEEE 50机145母线系统和中国某省简化系统案例,验证该方法的有效性和优越性.

## 1 预备知识

### 1.1 空间金字塔池化网络

CNN是目前最流行的有监督学习网络之一,可以直接在输入数据与暂态稳定性之间构造一种非线性

性映射关系.为进一步提高CNN对数据特征的信息挖掘能力,本文利用空间金字塔池化(spatial pyramid pooling, SPP)层<sup>[12]</sup>替换CNN最后一个池化层构建SPP-net. SPP不同于传统的池化操作,其通过多级池化来固定输出数据的尺寸,并提取输入特征图的多尺度特征,汇集较为全面的局部信息,可以有效提升CNN模型的性能.其中, SPP层每个池化窗的尺寸 $P_w$ 和滑动步长 $Str$ 是随特征图变化而变化的,即

$$P_w = \lceil F/n \rceil, \quad (1)$$

$$Str = \lfloor F/n \rfloor. \quad (2)$$

其中: $\lceil \cdot \rceil$ 和 $\lfloor \cdot \rfloor$ 分别为向上取整和向下取整, $F$ 为特征图尺寸, $n$ 为输出尺寸.

### 1.2 多层次特征融合

CNN作为一种多层的网络模型,其不同层级的特征信息分别对应输入对象不同的特征属性,如低层级特征包含识别对象的纹理、位置等细节信息,而高层级特征包含更为抽象的语义、结构等全局信息<sup>[18]</sup>.由于TSP模型的电力系统稳定性分类与稳定裕度预测需要更具特征性的高层级信息,而临界发电机识别还需要位置、轮廓等细节信息,本文利用跳跃链接(skip connections)<sup>[16,19]</sup>构建一种多层次特征融合网络,以充分利用数据的多层次特征属性提高TSP模型的预测精度,其结构如图1跳跃链接部分所示.不同层次特征采用适当尺寸的池化窗进行池化,进而经扁平化后在融合层进行特征融合,计算过程如下:

$$O_i = p(h_i), \quad (3)$$

$$O_{ML.fusion} = \text{flatten}([O_1, O_2, \dots, O_i]). \quad (4)$$

其中: $h_i$ 为第 $i$ 层的特征图, $p$ 为池化操作, $O_i$ 为池化输出, $O_{ML.fusion}$ 为融合层特征.

### 1.3 多任务学习

MTL是使神经网络学习多个任务的有效方法,其利用任务间的耦合关系和共享机制提升模型的泛化能力<sup>[11]</sup>,其中MTL共享机制主要分为硬参数共享和软参数共享.采用硬参数共享机制<sup>[20]</sup>的MTL模型使用同一特征共享层,经训练后得到一个通用的参数模型;而基于软参数共享机制MTL模型的每个任务都有各自的网络结构和参数,其中共享空间的网络层通过正则化方法使参数相似,以达到信息共享的目的.因此,通过结构和参数设置较为简单的硬参数共享,可构建适用于数据繁多、结构复杂且任务相关性紧密的TSP多任务模型.

进一步地,为使多个任务均收敛到最优,本文采用一种加权联合损失函数<sup>[20]</sup>,即

$$L = \sum_m^M K_m L_m + \frac{\lambda}{2} \sum_{q=W} w_q^2. \quad (5)$$

其中:  $\frac{\lambda}{2} \sum_{q=W} w_q^2$  为  $L_2$  正则项<sup>[21]</sup>,  $\lambda$  为正则化系数,  $w_q$  为学习层权重参数,  $W$  为所有学习层的权重参数集合,  $M$  为任务个数,  $L_m$  为第  $m$  个任务损失函数,  $K_m$  为第  $m$  个任务的损失权重.

## 2 基于MSPP-net的TSP模型

### 2.1 模型结构

根据上述方法建立MSPP-net模型. 本文主干网络采用传统卷积层构建, 通过SPP和跳跃链接分别获

取高层特征多尺度信息和不同卷积层特征信息. 多尺度、多层次特征在融合层融合, 并与全连接层1相连. 全连接层1输出可表示为

$$O_{fc.1} = w_{fc.1}[O_{SPP.fusion}, O_{ML.fusion}] + b_{fc.1} = w_{fc.1}O_{fusion} + b_{fc.1}. \quad (6)$$

其中:  $w_{fc.1}$  和  $b_{fc.1}$  分别为其全连接层1的权重和偏置,  $O_{fc.1}$  为全连接层1输出,  $O_{SPP.fusion}$  为SPP层融合的特征,  $O_{fusion}$  为融合层特征. 之后, 在输出层建立3个全连接层并采用相应的激活函数, 产生对应不同任务的输出结果. 详细结构如图1中MSPP-net模型结构部分所示.

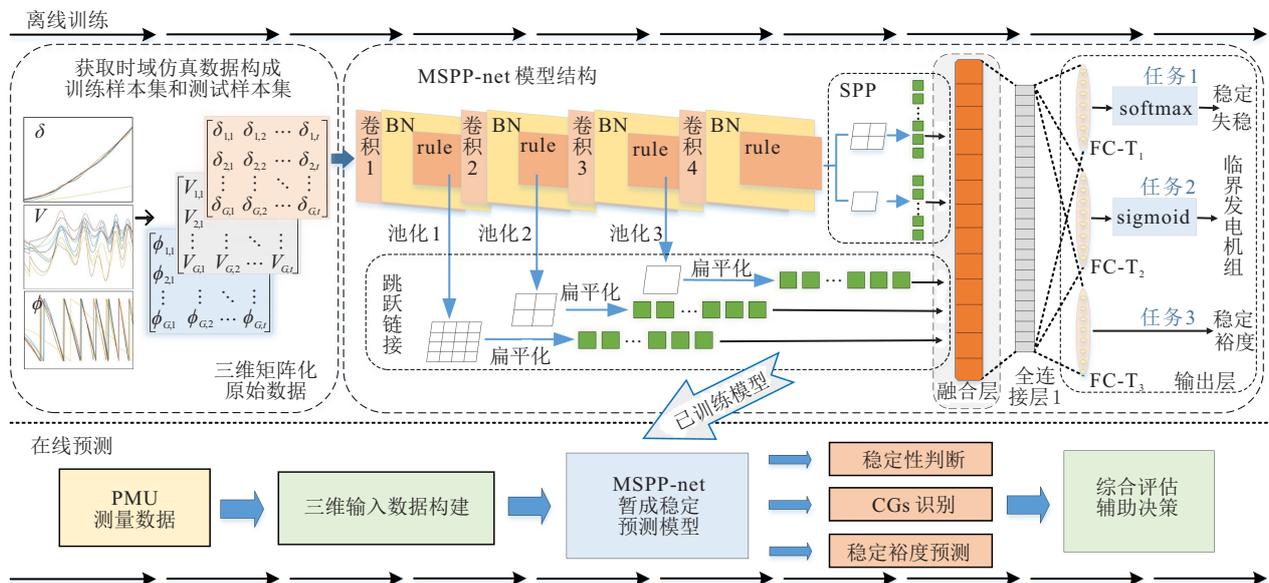


图1 所提基于MSPP-net的暂态稳定多任务预测流程

为提高训练速度, 加快收敛过程, 降低网络对参数初始化的敏感性, 本文在卷积层和激活函数之间加入 batch normalization (BN)<sup>[22]</sup> 层, 各层参数可见表1.

表1 MSPP-net模型结构参数

层名称	滤波器尺寸	滑动步长
输入层	10 × 10 × 3	—
卷积层1	3 × 3 × 3	1 × 1 × 1
池化层1	2 × 2 × 1	2 × 2 × 1
卷积层2	3 × 3 × 1	1 × 1 × 1
池化层2	3 × 3 × 1	3 × 3 × 1
卷积层3	3 × 3 × 1	1 × 1 × 1
池化层3	4 × 4 × 1	4 × 4 × 1
卷积层4	3 × 3 × 1	1 × 1 × 1
SPP层	1 × 1 × 1 2 × 2 × 1	1 × 1 × 1 2 × 2 × 1
融合层	1 664 × 1 × 1	—
全连接层1	400 × 1 × 1	—

### 2.2 特征选取

电力系统暂态稳定直接取决于发电机间的相对功角差, 同时与故障后发电机出力、负荷水平等系统动态特征息息相关, 则发电机功角的相关变量常被选为TSP模型的输入特征. 此外, 也有很多研究选择线路潮流或母线电压等易于测量的数据作为输入特征<sup>[9-10]</sup>. 因此, 本文选取发电机转子角度、发电机所在母线电压幅值和相角作为电力系统特征信息, 构成  $G \times N \times 3$  的三维输入数据. 其中:  $G$  为系统发电机台数,  $N$  为采样个数.

### 2.3 任务类型

快速准确地判断电力系统故障后能否保持同步运行是电网安全防控中的重要问题. 快速识别临界发电机(critical generators, CGs)是电网实时紧急控制措施决策依据的关键. 此外, 稳定裕度能够定量描述稳定的程度, 可为后续紧急控制提供参考信息. 因此, 本文将对这3类任务同时进行预测分析, 以提供更全

面的TSP结果.

对于任务1,暂态稳定性判断是一个二分类问题.为可靠获得系统稳定性状态,时域仿真持续5s,并采用暂态稳定指标(transient stability index, TSI)<sup>[8-9]</sup>进行判别,TSI为

$$\eta = \frac{360^\circ - |\Delta\delta|_{\max}}{360^\circ + |\Delta\delta|_{\max}}, \quad (7)$$

其中 $|\Delta\delta|_{\max}$ 为任意两台发电机功角差绝对值的最大值.若 $\eta$ 为正值,则系统稳定,标签为0;反之,若 $\eta$ 为负值,则系统失稳,标签为1.分类任务主要采用交叉熵损失函数<sup>[7,9]</sup>,即

$$L_1 = -\frac{1}{N} \sum_{n=1}^N [T_n^0 \log(Y_n^0) + T_n^1 \log(Y_n^1)]. \quad (8)$$

其中: $N$ 为样本数量, $T_n^0$ 、 $T_n^1$ 分别为样本的真实标签, $Y_n^0$ 、 $Y_n^1$ 分别为预测的稳定、失稳概率.

参考文献[10],本文将功角差偏离其余发电机 $360^\circ$ 的机组定义为CGs.对于任务2,CGs的识别是一个多标签分类问题.每个输入样本与一组标签相关联,假设系统有 $G$ 台发电机,则每个标签中有 $G$ 个子标签,每个子标签赋值1或0以表示对应发电机是或不是临界发电机.任务2采用sigmoid激活函数使每个子标签输出限制在 $[0, 1]$ 之间,当子标签输出大于0.5时,则对应的发电机被预测为临界发电机<sup>[10]</sup>.多标签分类常采用二元交叉熵作为损失函数,即

$$L_2 = -\frac{1}{N} \sum_{i=1}^N \sum_{j=1}^C (T_{i,j} \log(Y_{i,j}) + (1 - T_{i,j}) \log(1 - Y_{i,j})). \quad (9)$$

其中: $N$ 为样本数量, $Y$ 为sigmoid输出值, $T$ 为子标签实际值.

对于任务3,稳定裕度(stability margin, SM)的预测是一个拟合问题,可以由极限切除时间(critical clearing time, CCT)<sup>[8]</sup>与故障持续时间 $\Delta t$ 的差值得到稳定裕度,即

$$SM = CCT - \Delta t. \quad (10)$$

其中在电力系统不同情况下,CCT可通过二分法和大量时域仿真获取.

此外,任务3的损失函数采用均方根损失,如下所示:

$$L_3 = \sqrt{\frac{1}{N} \sum_{n=1}^N (Y_n - T_n)^2}. \quad (11)$$

其中: $N$ 为样本数量, $Y$ 为预测的稳定裕度值, $T$ 为实际的稳定裕度值.

进一步的,通过式(5)可得联合损失函数.根据任

务的重要程度和训练难易程度,设置3个任务权重 $k_1$ 、 $k_2$ 、 $k_3$ 分别为0.3、0.35、0.35.

## 2.4 评价指标

### 1) 任务1评价指标.

本文通过构造混淆矩阵评价模型分类效果,混淆矩阵如表2所示.

表2 混淆矩阵

样本	稳定(预测)	失稳(预测)
稳定(真实)	$T_s$	$F_{us}$
失稳(真实)	$F_s$	$T_{us}$

样本的预测准确率Acc、误报率FA及漏报率MA如下:

$$Acc = \frac{T_s + T_{us}}{T_s + T_{us} + F_s + F_{us}}, \quad (12)$$

$$FA = \frac{F_{us}}{T_s + F_{us}}, \quad (13)$$

$$MA = \frac{F_s}{T_{us} + F_s}. \quad (14)$$

在实际应用中,失稳样本的漏判产生的代价远远高于稳定样本的误判,所以应该更加重视实际为失稳的样本预测结果.此外,考虑误报率和漏报率在内的安全性和可靠性,定义Gmean指标为

$$Gmean = \sqrt{(1 - FA)(1 - MA)}. \quad (15)$$

### 2) 任务2评价指标.

任务2输出是一组CGs集合,可以使用Jaccard相似性<sup>[10,23]</sup>进行评估.定义两个一维二进制集合 $S_1 = [s_{1,1}, s_{1,2}, \dots, s_{1,i}, \dots, s_{1,G}]$ 与 $S_2 = [s_{2,1}, s_{2,2}, \dots, s_{2,i}, \dots, s_{2,G}]$ 之间的Jaccard相似性为

$$J(S_1, S_2) = \frac{|S_1 \cap S_2|}{|S_1 \cup S_2|} = \frac{\sum_i s_{1,i} s_{2,i}}{\sum_i s_{1,i}^2 + \sum_i s_{2,i}^2 - \sum_i s_{1,i} s_{2,i}}. \quad (16)$$

其中: $J \in [0, 1]$ , $S_1$ 为实际CGs的集合, $S_2$ 为本文模型预测的CGs的集合.只有当 $J = 1$ 时,表示任务2预测正确,采用Jacc表示任务2的正确率.

### 3) 任务3评价指标.

暂态稳定裕度预测的评价指标为均方误差,其能够衡量对稳定裕度的预测精度,表达式如下:

$$emse = \frac{1}{N} \sum_{i=1}^N (Y_i - T_i)^2. \quad (17)$$

其中: $N$ 为测试样本总数, $Y$ 为稳定裕度预测值, $T$ 为

稳定裕度真实值.

### 2.5 所提MSPP-net暂态稳定预测方法流程

所提基于MSPP-net模型的暂态稳定多任务预测流程如图1所示,其分为离线训练和在线评估两部分. 离线训练过程:通过时域暂态仿真获取不同运行工况下故障切除后的发电机功角、机端母线电压幅值和相角的短时扰动轨迹,构成3维输入数据样本,同时根据TSI和CCT确定样本的稳定类别标签、临界发电机和稳定裕度. 进而构造出MSPP-net暂态稳定预测模型,并将样本数据分为训练集和测试集,通过训练模型调整网络参数,使模型的性能达到最优. 在线评估过程:故障切除后,立即从实时量测系统获取相应的电气量数据,利用完成训练的MSPP-net模型进行暂态稳定多任务预测.

## 3 算例分析

### 3.1 2个IEEE标准案例

为验证所提方法的有效性和适用性,本文案例主要在一个IEEE 10机39母线系统展开,考虑在大规模系统应用的有效性,对IEEE 50机145母线系统进行实验. IEEE 50机145节点系统包括50台发电机、145条母线、453条支路. 基准功率为100 MVA,额定频率为50 Hz. 设置三相短路故障在除变压器所在支路外其他401条支路上;故障位置在每条线路长度的25%和75%处;负荷水平在80%~120%(以10%为变化步长)的基准负荷间变化,并调整发电机出力使潮流收敛;故障持续时间为0.1~0.4 s(变化步长为0.02 s). 在仿真0.1 s处发生故障,仿真时长为5 s,采样频率为0.01 s. 得到23 424个有效样本,稳定样本14 528个,失稳样本8 896个. 随机抽取20 000个样本,18 000个作为训练集,2 000个作为测试集. IEEE 50机145母线系统实验结果如表3~表5、图2和图3所示.

表3 IEEE 50机算例下不同结构CNN模型的预测结果

模型	Acc / %	Jacc / %	emse
MSPP-net	99.45	96.25	0.001 8
SPP-net	98.70	94.75	0.002 3
MCNN	98.65	92.35	0.004 4
SCNN	97.95	91.70	0.004 6

表4 IEEE 50机算例下不同分类模型性能比较

算法模型	Acc / %	FA / %	MA / %	Gmean
MSPP-net	99.45	0.23	1.07	0.993 5
SAE	98.70	0.95	2.02	0.985 2
Bi-LSTM	97.38	1.93	3.74	0.971 6
KNN	93.38	1.10	14.23	0.930 3
SVM	97.66	1.69	3.19	0.975 6
DT	97.38	2.13	3.52	0.971 7
RF	98.19	0.91	3.42	0.978 3

表5 PMUs非100%覆盖模型预测结果

PMUs 覆盖率 / %	Acc / %	FA / %	MA / %	Gmean / %	Jacc / %	emse
90	99.20	0.66	1.02	0.991 6	95.30	0.002 6
80	98.85	0.73	1.82	0.987 2	94.95	0.002 5
60	98.65	1.04	1.87	0.985 4	93.50	0.003 8
40	98.55	1.06	2.06	0.984 4	93.30	0.004 3
20	96.05	2.27	6.63	0.955 3	90.35	0.008 3

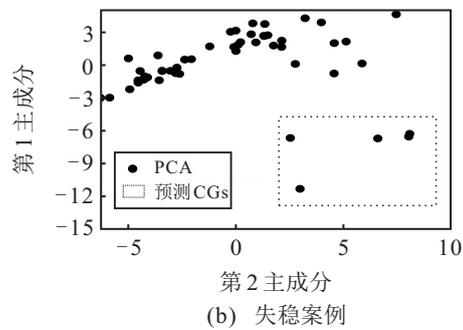
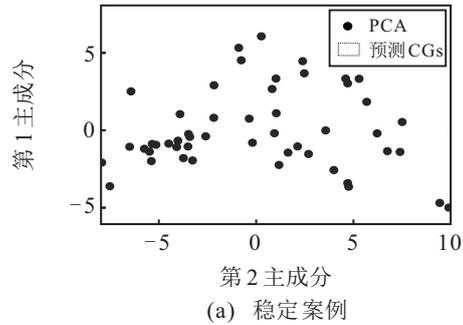


图2 IEEE 50机算例的临界发电机可视化

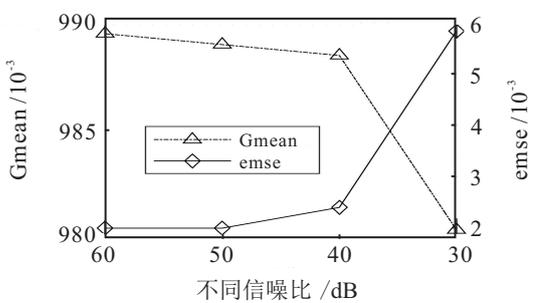
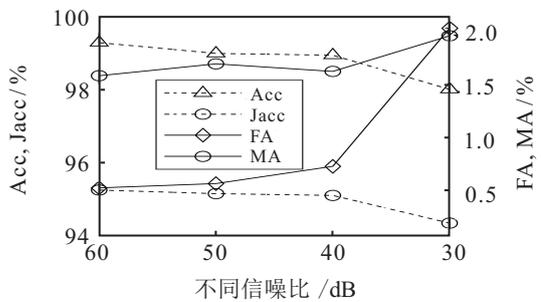


图3 IEEE 50机算例的抗噪性测试结果

在10机系统中,考虑负荷水平在85%~120%(以5%为变化步长)的基准负荷间变化,并调整发电机出力使潮流收敛. 设置三相短路故障在除变压

器所在支路外的其他34条支路上,故障位置在每条线路长度的20%、40%、60%和80%处.故障持续时间为0.02~0.2s(变化步长为0.02s).其中,在仿真0.1s处发生故障,仿真时长为5s.借助Matlab和PST 3.0<sup>[24]</sup>开展时域仿真,获取共计样本10880个,其中稳定样本7031个,失稳样本3849个.将数据集随机分为训练集和测试集,进行10次,实验结果取平均值.其中:训练集8500个样本,测试集2380个样本.

利用Matlab R2020a软件在一台配备Intel(R) Core(TM) i7-8700 CPU/16.00 GB RAM的计算机测试了所提模型的性能.输入数据为故障清除后的5个周波(0.1s)内的发电机功角、发电机所在母线电压幅值与相角构成的 $10 \times 10 \times 3$ 的三维数据矩阵.模型训练参数设置:初始学习率为0.001,Epochs为90次,每20次学习率乘以0.5,MiniBatchSize为256.优化算法采用自适应矩估计(Adam),池化采用平均池化.

### 3.1.1 TSP模型的有效性测试

1)不同结构CNN模型的性能测试.为了验证MSPP-net模型的性能优势,与仅采用SPP的CNN(spatial pyramid pooling network, SPP-net)多任务模型、CNN多任务模型(multi-task CNN, MCNN)、CNN单任务模型(single-task CNN, SCNN)以及文献[10]的CNN模型(Y-net)进行比较,预测结果如表6所示.

表6 IEEE 10机算例下不同结构CNN模型的预测结果

模型	Acc/%	FA/%	MA/%	Gmean	Jacc/%	emse
MSPP-net	99.87	0.07	0.24	0.9985	99.25	0.0003
SPP-net	99.69	0.34	0.42	0.9962	98.38	0.0004
MCNN	99.69	0.11	0.62	0.9964	97.74	0.0007
Y-net	99.33	0.59	0.83	0.9929	97.21	-
SCNN	99.15	0.62	1.15	0.9910	95.96	0.0008

由表6可知,Y-net与MCNN的预测精度优于单任务模型SCNN,说明MTL方法有效提高了模型的学习能力.MCNN的Acc和Jacc分别比Y-net的高0.36%和0.53%,说明文献[10]构建的网络较浅,性能较低.而在多任务基础上加入SPP构建SPP-net模型,其在任务2和任务3方面的预测精度有了较大提升.进一步的,在SPP-net基础上加入多层次特征构建本文MSPP-net模型.与SPP-net相比,MSPP-net的Acc提高了0.18%,Jacc提高了0.87%,MA约为SPP-net的1/2,稳定裕度预测误差降低了0.0001.综上,本文模型能够有效识别暂态稳定与否、临界发电机组及精确预测暂态稳定裕度,且相比传统CNN模型具有较高的预测精度.究其原因,所构建的MSPP-net可以通过多层次、多尺度特征提取获得更多细节信息,且多任务特征共享机制避免了过拟合,提高了模型的泛化能力.此外,表3结果显示,应用于50机系统案例

时仍能得到与上述一致的结论,且相比于10机系统案例,所提MSPP-net模型性能提升更为明显.

2)不同分类模型的性能测试.为展现本文模型比传统浅层学习和深度学习方法在任务1方面的优势,分别与堆叠自编码器(SAE)、双向长短时记忆法(Bi-LSTM)<sup>[25]</sup>、支持向量机(SVM)、 $k$ -最邻近(KNN)、决策树(DT)和随机森林(RF)进行比较.由于这几种算法的输入是一维向量,在训练前将输入数据进行变形,并调节参数使其效果最优.其中:SAE隐含层结构为(100,50);Bi-LSTM隐层单元数为(256,128,50);KNN经寻优后, $k$ 选为20;SVM采用RBF作为核函数,采用网格法和五折交叉验证进行相关参数寻优;DT采用分类回归树(CART)算法;RF采用70棵树集成.实验结果如表7所示.

表7 不同模型的预测结果

分类模型	Acc/%	FA/%	MA/%	Gmean
MSPP-net	99.87	0.07	0.24	0.9985
SAE	99.01	0.71	1.56	0.9887
Bi-LSTM	98.52	0.32	4.20	0.9772
KNN	96.77	1.93	8.14	0.9491
SVM	98.83	0.13	3.49	0.9818
DT	98.45	0.56	3.70	0.9784
RF	98.83	0.19	3.11	0.9834

由表7可知:一方面,KNN,SVM,DT,RF属于浅层学习模型,其中RF预测效果最好,然而,本文模型Acc、Gmean比RF高1.04%和0.0151,MA约为RF的1/13;另一方面,Bi-LSTM、SAE属于深度学习模型,其中SAE性能最佳,它的Acc为99.01%、Gmean为0.9887,而本文MSPP-net模型的Acc和Gmean分别比SAE的高0.86%和0.098,且MA约为SAE的1/7.这说明采用SPP和多层次特征进一步提高了模型特征提取能力,更易挖掘电力系统暂态输入数据与暂稳输出结论之间的非线性映射关系.此外,表4结果显示,应用于50机系统案例时,本文模型仍然优于其他模型.

3)临界发电机识别.为了可视化在任务2中识别的临界发电机组,本文通过主成分分析(principal component analysis, PCA)<sup>[26]</sup>得到输入数据前两个主成分,并投影到由第1、第2主成分张成的二维空间上,得到可视化图,如图4所示.其中:蓝色实心圆表示PCA可视化后的发电机,红色实线方框表示本文模型预测的CGs.

观察图4(a)中失稳情况下PCA可视化结果,可见发电机4、发电机5显著偏离了其余机组,且MSPP-net模型正确识别出了临界发电机.图4(b)为本文模型预测的稳定案例.通过PCA可视化后可以看出,发电机分布零散且均匀,没有显著离群的机组.在应用

于50机系统案例时(如图2所示),所提方法仍可准确识别CGs. PCA可视化和本文模型可以直观地展现出发电机离群情况,且PCA可以校验所提模型对CGs的识别准确率,进一步提高预测的可靠性.

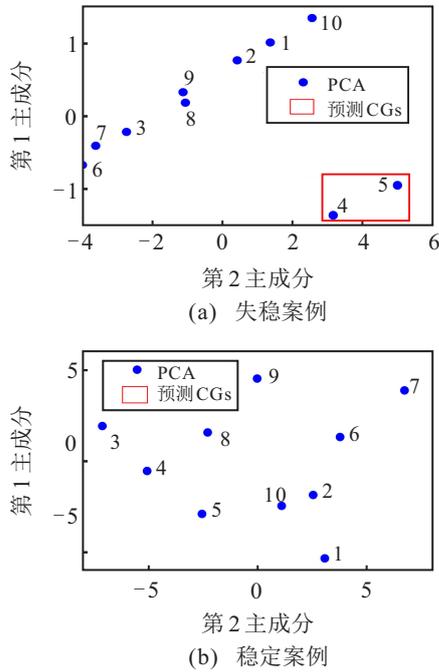


图4 IEEE 10机算例的临界发电机可视化

3.1.2 TSP模型鲁棒性测试

1) TSP模型抗噪性能测试. 为验证模型的抗噪性能,在测试数据中加入信噪比分别为50 dB、40 dB、30 dB的高斯白噪声<sup>[3]</sup>,然后用训练好的模型进行测试,与3.1.1节中的SPP-net、MCNN和SCNN模型进行比较,预测结果如表8所示.

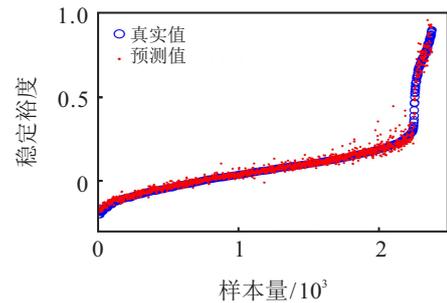
表8 含噪声时的预测结果

SNR/dB	模型	Acc / %	Gmean	Jacc / %	emse
50	MSPP-net	99.64	0.9960	98.60	0.0005
	SPP-net	99.43	0.9939	98.27	0.0005
	MCNN	99.43	0.9937	97.29	0.0010
	SCNN	98.49	0.9845	95.03	0.0013
40	MSPP-net	99.59	0.9940	98.60	0.0014
	SPP-net	99.30	0.9920	97.95	0.0015
	MCNN	98.90	0.9840	96.45	0.0017
	SCNN	98.36	0.9810	94.65	0.0020
30	MSPP-net	97.72	0.9737	97.35	0.0065
	SPP-net	97.56	0.9728	95.83	0.0091
	MCNN	97.07	0.9684	94.24	0.0089
	SCNN	96.76	0.9665	93.03	0.0102

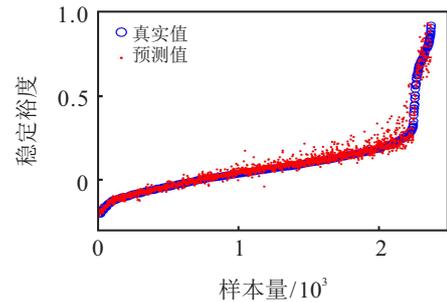
随着噪声的增加,各个模型的预测性能降低,但MSPP-net模型预测指标仍优于其他模型. 在50 dB和30 dB的预测结果比较下:在任务1方面,本文模型Acc和Gmean在不同信噪比下均高于其他模;在任务2方面,所提模型Jacc降低了1.25%,其下降幅度最小,而另外3种模型Jacc下降幅度均多于2.00%;在任务

3方面,本文模型emse增加了0.006,而另外3种模型的emse增加幅度约为本文模型的1.3~1.5倍. 当信噪比为30 dB时,本文模型Acc和Jacc仍能达到97%以上,且emse远小于其他模型.

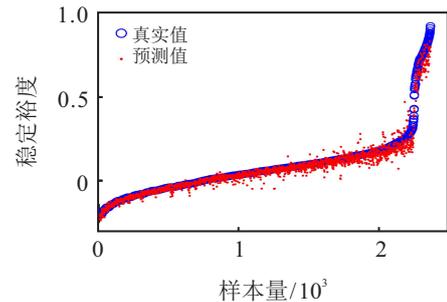
图5为50 dB下稳定裕度预测情况,可以看出,在稳定裕度预测方面,本文方法更加优越. 此外,图3所示的50机系统案例抗噪性能测试中,所提MSPP-net在较低信噪比环境下,仍可得到较好的预测精度. 实验结果说明本文采用多任务学习、多尺度与多层次特征融合的方法有效提高了CNN暂态稳定预测模型的抗噪性能.



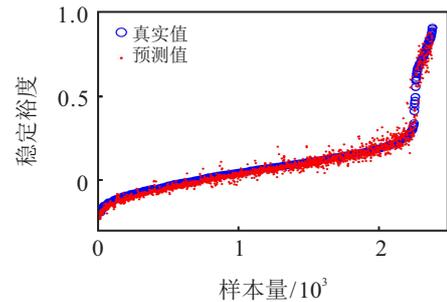
(a) 所提模型SM预测结果



(b) SPP-net模型SM预测结果



(c) MCNN模型SM预测结果



(d) SCNN模型SM预测结果

图5 50 dB噪声环境下稳定裕度预测结果

2) PMUs非100%覆盖下TSP模型性能测试. 在实际输电系统中PMUs不可能100%覆盖, 通常只在部分重要发电机装设PMUs, 因此考虑部分机组未装设PMUs, 本文令该机组对应的输入数据置零, 重新训练模型进行测试. 由于缺失发电机信息的排列组合情况很多, 本文根据文献[7]的实验结果构造了7种包含发电机信息的集合, 如表9所示.

表9 包含发电机信息的集合组成

集合	所包含发电机
1	G <sub>1</sub> 、G <sub>2</sub> 、G <sub>3</sub> 、G <sub>4</sub> 、G <sub>5</sub> 、G <sub>6</sub> 、G <sub>7</sub> 、G <sub>8</sub> 、G <sub>9</sub> 、G <sub>10</sub>
2	G <sub>1</sub> 、G <sub>2</sub> 、G <sub>4</sub> 、G <sub>5</sub> 、G <sub>7</sub> 、G <sub>8</sub> 、G <sub>9</sub>
3	G <sub>1</sub> 、G <sub>2</sub> 、G <sub>5</sub> 、G <sub>7</sub> 、G <sub>8</sub> 、G <sub>9</sub>
4	G <sub>2</sub> 、G <sub>3</sub> 、G <sub>7</sub> 、G <sub>8</sub> 、G <sub>9</sub>
5	G <sub>3</sub> 、G <sub>5</sub> 、G <sub>7</sub> 、G <sub>9</sub>
6	G <sub>7</sub> 、G <sub>8</sub> 、G <sub>9</sub>
7	G <sub>8</sub> 、G <sub>9</sub>

图6为缺失部分发电机信息时的实验结果, 随着PMUs覆盖率降低, 3个任务的预测精度逐渐下降. 就任务1而言, 覆盖发电机台数大于2时, 本文预测模型的Acc和Gmean精度均在99%以上, FA低于0.5%, MA低于1.96%. 当覆盖发电机台数为2台时, Acc和Gmean的精度有了较大的下降, Acc为95.5%左右, 同时MA也大幅增加, 而FA变化较为平稳, 一直低于0.5%. 就任务2和任务3而言, 当覆盖发电机台数大于2台时, Jacc精度在97.4%以上, emse低于0.002. 而当覆盖发电机台数为2台时, Jacc大幅下降到93%, emse增加到0.005, 增加了2.5倍.

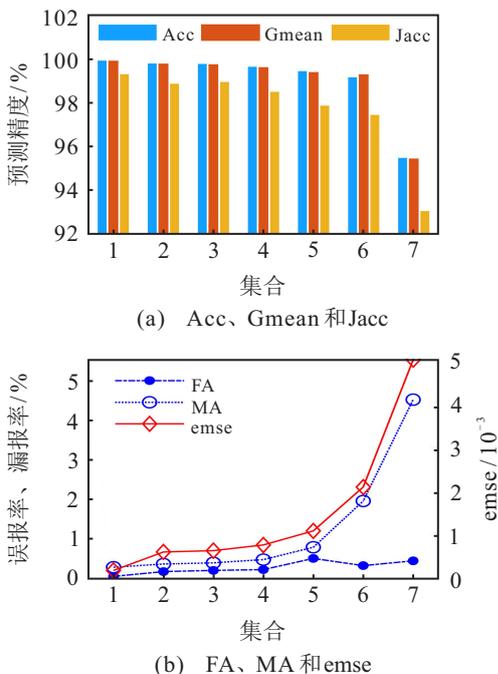


图6 发电机信息缺失时模型的预测结果

由于本文的模型输入数据是有关发电机信息的源数据, 当缺失发电机台数过多时, TSP模型预测准

确率会降低, 但任务1中Acc仍高于95%, 尤其当缺失信息发电机台数小于8台时, Acc可达99%以上. 此外, 如表5所示, 在50机系统案例中PMUs覆盖率较低时, 预测结果仍可接受, 这说明本文MSPP-net模型在PUMs非100%覆盖时的非完整信息下仍具有较强的鲁棒性.

### 3.2 中国某省简化系统案例分析

为了验证所提方法在实际电网中的有效性, 以中国某省简化系统为例进行分析, 其中包括16个发电厂、64条线路、13个500kV变电站, 地理接线示意图如图7所示.

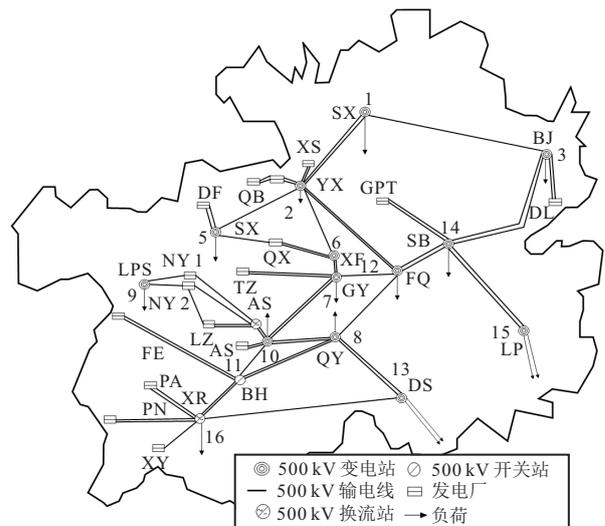


图7 中国某省简化系统500kV地理接线

与IEEE 10机39母线系统中的仿真设置类似, 考虑不同负荷水平、故障位置和故障持续时间. 采用PSAT<sup>[27]</sup>进行时域仿真, 共得到9458个有效样本, 包括6352个稳定样本, 3106个失稳样本. 随机将样本分成训练集和测试集, 训练集为8458个样本, 测试集为1000个样本.

#### 3.2.1 TSP模型有效性测试

将MSPP-net模型与3.1.1节中SPP-net、MCNN和SCNN进行比较, 实验结果如表10所示.

表10 实际算例下不同结构CNN模型的预测结果

模型	Acc / %	Jacc / %	emse
MSPP-net	99.60	97.70	0.0008
SPP-net	99.40	94.80	0.0010
MCNN	99.20	92.30	0.0013
SCNN	98.80	90.10	0.0010

从表10内容可知, 所提MSPP-net模型在3个任务方面均优于其他模型. 尤其在任务2方面, MSPP-net分别比SPP-net、MCNN和SCNN高出2.9%、5.4%和7.6%, 性能提升明显. 此外, 与较为传统的单任务模型SCNN相比, Acc提高了0.8%, emse约为SCNN

的1/2,性能提升较为显著.

图8为临界发电机可视化结果.图8(a)为稳定案例可视化结果,可以看出发电机分布均匀,没有显著的离群值.图8(b)为失稳案例可视化结果,可以看出有两台发电机远离其他发电机群,MSPP-net模型也预测出相应的CGs.实验结果表明,本文模型在实际案例应用中具有一定的有效性.

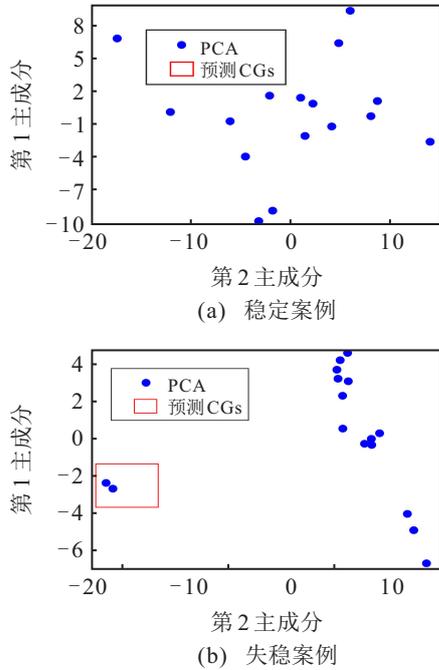


图8 实际算例的临界发电机可视化

3.2.2 TSP模型鲁棒性测试

在测试集加入不同信噪比的噪声,验证模型的抗噪性能,实验结果如图9(a)所示.

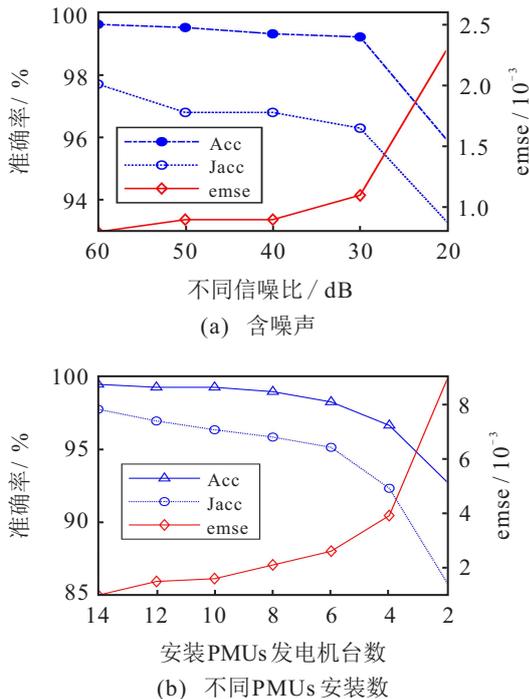


图9 鲁棒性测试结果

随着信噪比的降低,预测精度也逐渐降低.虽然在信噪比为20dB时,预测精度大幅下降,Acc为95.9%,Jacc为93.3%,emse为0.0023.但在信噪比大于30dB时,对模型的预测精度影响较小,Acc高于99%,Jacc高于96%,emse小于0.0015.实验结果表明,在实际案例中,较低信噪比下本文模型仍能得到较为理想的预测精度.

考虑PMUs未100%覆盖对TSP结果的影响,设置不同安装PMUs的发电机数进行实验分析,结果如图9(b)所示.随着PMUs覆盖率降低,3个任务的预测精度也逐渐降低.当安装PMUs的发电机数大于6时,Acc高于98.2%,Jacc大于95.1%,emse小于0.0026.结果表明,在实际案例中PMUs安装数较低时,本文模型仍可达到一定的预测精度.当安装数小于6时,预测精度有了明显下降.由于PUMs安装少,得到的发动机信息有限,导致预测精度下降.尤其只有2台发电机安装PMU时,Acc为92.7%,Jacc仅为85.8%.

4 结论

本文提出了一种基于MSPP-net的暂态稳定多任务预测模型.一个IEEE 10机39母线、一个IEEE 50机145母线系统和中国某省简化系统的仿真实验结果表明:1)本文利用多层次特征和SPP,增强了模型的特征提取能力,进一步提高了模型的预测精度.与传统CNN模型相比,所提模型预测准确率更高,鲁棒性能更好.2)所提方法可以实时、准确地实现电力系统暂态稳定性的判断、临界发电机识别和稳定裕度预测,从而可提供较为全面的辅助决策信息.3)在噪声环境下或PMUs覆盖率较低时,本文模型在3个任务预测方面仍可达到较为理想的预测精度.

参考文献(References)

- [1] Ma L Z, Chen X B. Distributed coordination control and transient connective stability of networked multi-machine power systems[J]. Control and Decision, 2017, 32(11): 1980-1984.
- [2] Wang R, Zhang Y, Wang D, et al. Optimization and scheduling of power system stochastic model predictive control based optimization and scheduling for power system with large scale wind integrated[J]. Control and Decision, 2019, 34(8): 1616-1625.
- [3] Li H Q, Han S, Zhou Z Q. Eigen characteristic of sample covariance matrix based multi-disturbance positioning method of power system[J]. Transactions of China Electrotechnical Societ, 2021, 36(3): 646-655.
- [4] Xi L, Zhou L, Liu L. A deep reinforcement learning algorithm for the power order optimization allocation of AGC in interconnected power grids[J]. CSEE Journal of Power and Energy Systems, 2020, 6(3): 712-723.

- [5] An J, Ai S Q, Liu D W, et al. A power system transient stability assessment method based on short-time disturbed trajectories[J]. *Power System Technology*, 2019, 43(5): 1690-1697.
- [6] 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.  
(Tian F, Zhou X X, Shi D Y, et al. Power system transient stability assessment based on comprehensive convolutional neural network model and steady-state features[J]. *Proceedings of the CSEE*, 2019, 39(14): 4025-4032.)
- [7] Zhou Y Z, Guo Q L, Sun H B, et al. A novel data-driven approach for transient stability prediction of power systems considering the operational variability[J]. *International Journal of Electrical Power & Energy Systems*, 2019, 107: 379-394.
- [8] Zhu L P, 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.
- [9] Zhang R Y, Wu J Y, Xu Y, et al. A hierarchical self-adaptive method for post-disturbance transient stability assessment of power systems using an integrated CNN-based ensemble classifier[J]. *Energies*, 2019, 12(17): 3217.
- [10] Gupta A, Gurralla 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.
- [11] Zhang Y, Yang Q. An overview of multi-task learning[J]. *National Science Review*, 2018, 5(1): 30-43.
- [12] He K M, Zhang X Y, Ren S Q, et al. Spatial pyramid pooling in deep convolutional networks for visual recognition[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2015, 37(9): 1904-1916.
- [13] 林君豪,张焰,赵腾,等. 基于改进卷积神经网络拓扑特征挖掘的配电网结构坚强性评估方法[J]. *中国电机工程学报*, 2019, 39(1): 84-96.  
(Lin J H, Zhang Y, Zhao T, et al. Structure strength assessment method of distribution network based on improved convolution neural network and network topology feature mining[J]. *Proceedings of the CSEE*, 2019, 39(1): 84-96.)
- [14] Wang X L, Wang S, Cao J Q, et al. Data-driven based tiny-YOLOv3 Method for front vehicle detection inducing SPP-net[J]. *IEEE Access*, 2020, 8: 110227-110236.
- [15] Zhao H S, Shi J P, Qi X J, et al. Pyramid scene parsing network[C]. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Honolulu: IEEE, 2017: 2881-2890.
- [16] Ren Y, Huang J S, Hong Z Y, et al. Image-based concrete crack detection in tunnels using deep fully convolutional networks[J]. *Construction and Building Materials*, 2020, 234: 117367.
- [17] Huang Z C, Wang J L, Fu X S, et al. DC-SPP-YOLO: Dense connection and spatial pyramid pooling based YOLO for object detection[J]. *Information Sciences*, 2020, 522: 241-258.
- [18] Zeiler M D, Fergus R. Visualizing and understanding convolutional networks[C]. *European Conference on Computer Vision*. Cham: Springer, 2014: 818-833.
- [19] Qi F, Lin C H, Shi G M, et al. A convolutional encoder-decoder network with skip connections for saliency prediction[J]. *IEEE Access*, 2019, 7: 60428-60438.
- [20] Dong Y L, Cao H Q, Ding X J, et al. Multi-task learning method for classification of multiple power quality disturbances[J]. *IET Generation, Transmission & Distribution*, 2020, 14(5): 900-909.
- [21] Goodfellow I, Bengio Y, Courville A. *Deep learning*[M]. Cambridge: The MIT Press, 2016: 228-269.
- [22] Ioffe S, Szegedy C. Batch normalization: Accelerating deep network training by reducing internal covariate shift[C]. *International Conference on Machine Learning*. Lille: International Machine Learning Society, 2015: 448-456.
- [23] 李晓庆,唐昊,司加胜,等. 面向混合属性数据集的改进半监督FCM聚类方法[J]. *自动化学报*, 2018, 44(12): 2259-2268.  
(Li X Q, Tang H, Si J S, et al. An improved semi-supervised FCM clustering method for mixed data sets[J]. *Acta Automatica Sinica*, 2018, 44(12): 2259-2268.)
- [24] 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.
- [25] 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.  
(Sun L X, Bai J T, Zhou Z Y, et al. Transient stability assessment of power system based on bi-directional long-short-term memory network[J]. *Automation of Electric Power Systems*, 2020, 44(13): 64-72.)
- [26] Anaparthi K K, Chaudhuri B, Thornhill N F, et al. Coherency identification in power systems through principal component analysis[J]. *IEEE Transactions on Power Systems*, 2005, 20(3): 1658-1660.
- [27] Milano F. An open source power system analysis toolbox[J]. *IEEE Transactions on Power Systems*, 2005, 20(3): 1199-1206.

## 作者简介

陈庆超(1995—),男,硕士生,从事深度学习在电力系统稳定分析中应用的研究, E-mail: 1203740864@qq.com;

韩松(1978—),男,教授,博士,从事交直流电力系统动态分析、新型电力电子装备以及配电网规划等研究, E-mail: shan@gzu.edu.cn;

毛钧毅(1995—),男,硕士生,从事基于随机矩阵理论的电力系统态势感知、深度学习在电力系统暂态稳定预测的应用的研究, E-mail: 245010318@qq.com.