

基于 CBAM-CNN 多任务模型的暂态电压稳定定量评估方法

容景超, 毛晓明, 王 炫, 林权辉, 杨炳鑫
(广东工业大学自动化学院, 广州 510006)

摘 要: 为提升基于数据的暂态电压稳定评估的时效性并实现定量评估, 提出一种基于卷积块注意力模块-卷积神经网络(convolutional block attention module-based convolutional neural network, CBAM-CNN)的暂态电压稳定评估模型。该模型以电网潮流数据、故障位置信息和节点电压突变信息为输入, 引入混合注意力机制和多任务学习框架, 输出电网各节点的暂态电压稳定水平和稳定标签。在经典 IEEE 39 节点系统中的研究表明, 所提出的模型对潮流和故障位置变化具有充分的适应性; 与其他几种常用的深度学习模型相比, 所推荐的模型具有更强的信息表征能力和泛化能力, 有望应用于电网预防控制策略的制订中。

关键词: 暂态电压稳定; 定量评估; 多任务学习; 注意力机制; 卷积神经网络; 深度学习

Quantitative Evaluation Method for Transient Voltage Stability Based on CBAM-CNN Multi-task Model

RONG Jingchao, MAO Xiaoming, WANG Xuan, LIN Quanhui, YANG Bingxin
(School of Automation, Guangdong University of Technology, Guangzhou 510006, China)

Abstract: To improve the timeliness of data-based transient voltage stability assessment and to achieve quantitative evaluation, we proposed a transient voltage stability evaluation model based on convolutional block attention module-based convolutional neural network (CBAM-CNN). In the model, the power-flow, fault location, and bus voltage jump information are used as inputs, and hybrid attention mechanism and multi-task learning framework are introduced to output the transient voltage stability level and stability labels of each node in power grid. Studies in the classic IEEE 39-bus system show that the proposed model has sufficient adaptability to changes in power-flow and fault location; compared to several other popular deep-learning models, the recommended model has stronger information representation and generalization capabilities, and is expected to be applied in power system preventive controls.

Key words: transient voltage stability; quantitative evaluation; multi-task learning; attention mechanism; convolutional neural network; deep learning

0 引言

我国主要负荷中心电网负荷高度密集, 依靠多回直流从区外集中送电, 且新能源发电占比不断提高。这些发展趋势导致本地同步电源不足, 电网暂态电压稳定性问题日益突出^[1-4]。

快速可靠的暂态电压稳定评估(transient voltage stability assessment, TVSA)是电网安全稳定控制的基础^[5]。电力系统电压稳定问题多为局部性问题。为给电网安全稳定控制提供充分的参考, TVSA 应

能具体到每个节点, 因此评估难度比功角稳定更大。

目前, TVSA 可分为基于机理和基于数据两类评估方法。基于机理的方法中时域仿真法最为成熟, 但求解较为耗时; 能量函数法评估效率高, 但结果偏于保守且只适用于较为简单的系统模型^[6-8]。随着大数据理论的发展以及广域测量技术的成熟, 基于数据驱动的暂态电压稳定评估成为研究热点。

文献[9]采用稳态潮流信息作为输入特征, 基于随机权重神经网络(neural networks with random weights, NNRW)的集成学习建立了暂态电压稳定分层评估模型, 先进行定性判断, 如果不发生电压崩溃再给出系统暂态电压稳定水平。文献[10-11]利用信息增益、信息增益率等指标从时序数据集中提取

基金资助项目: 广东省自然科学基金(2023A1515010716; 2020B1515130001)。
Project supported by Natural Science Foundation of Guangdong Province (2023A1515010716, 2020B1515130001).

出最具类别分辨能力的特殊子序列 shapelet, 再通过计算原始时间序列与 shapelet 的距离将原始信息转换为扁平数值式距离数据, 最后通过决策树对距离数据集进行挖掘学习, 从而实现全系统暂态电压稳定性的二分类判断。上述研究使用浅层机器学习模型作为分类器。

深度学习模型拥有浅层网络无法比拟的特征提取能力与应用泛化能力, 可有效提升评估效率与准确度。文献[12-14]使用卷积神经网络(convolutional neural network, CNN)对暂态电压稳定性进行评估。其中, 文献[12-13]使用静态信息作为输入, 文献[14]则使用稳态、故障发生及切除时刻的信息作为输入; 文献[12]输出系统的暂态稳定水平, 文献[13-14]则分别输出区域和系统暂态电压稳定标签。文献[15]以各节点的功率和电压时序值作为输入, 通过长短期记忆(long short term memory, LSTM)网络实现了系统暂态电压稳定性的定性评估。文献[16]以稳态、故障发生和切除时刻的节点状态为输入, 基于图嵌入算法考虑电网拓扑特征, 通过多任务学习机制, 同时给出暂态功角稳定性和多节点暂态电压稳定性的二分类评估结果。

上述智能评估系统取得了不错的效果, 但存在以下不足: 1) 大部分研究选用故障后电网的时序特征量作为输入[10-11,14-16], 虽能提升评估的精度, 但影响了评估的时效性。2) 基于电网静态信息建立的智能评估系统要么为每个故障分别建立评估模型[9,12], 要么在一个模型中考虑少量故障[13], 难以适应大电网的扰动规模。3) 大部分研究只能实现系统或区域代表性节点是否暂态电压稳定的定性或定量预测; 少数研究实现了多节点稳定性的定性评估[16]; 而几乎没有成果能量化各节点的暂态电压稳定水平, 因此难以以为暂态电压安全控制提供充分的参考。

本文提出一种基于卷积块注意力模块-卷积神经网络(convolutional block attention module-based convolutional neural network, CBAM-CNN)的暂态电压稳定定量评估模型。该模型以电网潮流信息、故障位置信息和电压突变信息为输入, 对潮流和扰动位置变化具有适应性; 引入混合注意力机制 CBAM 优化 CNN, 设计多任务学习框架, 采用动态加权平均策略优化模型的训练过程, 能同时输出多节点的暂态电压稳定水平和稳定标签。最后, 在经典的 10 机 39 节点系统进行仿真研究, 以验证所建模型的有效性与优越性。

1 CBAM-CNN 的基本原理

卷积神经网络 CNN 是一种应用很广的深度学习模型, 已有较多文献对其基本原理进行介绍, 本文不再赘述。已有研究表明, CNN 应用于电力系统安全评估领域有充分的可行性[12-14]。

本文的目标是建立一种可靠的、能适应扰动位置变化、能输出各节点安全水平、不依赖故障后暂态信息的暂态电压稳定评估模型, 对数据处理能力的要求很高。为此, 本文引入混合注意力机制 CBAM[17]来优化 CNN。注意力机制是近几年深度学习领域的研究热点, 其目标是让评估模型能关注到更为关键的特征, 从而提升模型的性能。

CBAM 是一种直接有效的注意力模块, 一般会被嵌入到池化层的前、后部分, 其结构上依次应用了通道注意力(channel attention module, CAM)和空间注意力(spatial attention module, SAM)两种机制, 以识别输入特征的重要程度并调整其占用比, 从而优化网络内的信息流动。CBAM 的结构如图 1 所示。

图 1 中, 维度为 $Z \times H \times W$ 的输入特征 F 先与通道注意力权重 $M_c(F)$ 进行同位元素相乘, 得到输出 F' ; F' 再与空间注意力权重 $M_s(F')$ 进行同位元素相乘, 得到 CBAM 的最终输出 F'' , 表达式为:

$$\begin{cases} F' = M_c(F) \otimes F \\ F'' = M_s(F') \otimes F' \end{cases} \quad (1)$$

式中: $\otimes$ 表示同位元素相乘。

CAM 的结构如图 2 所示, 输入特征经全局平均池化、全连接层运算和全局最大池化、全连接层运算, 所得结果求和后再经 sigmoid 激活函数, 生成维度为 $Z \times 1 \times 1$ 的通道注意力权重 $M_c(F)$:

$$M_c(F) = \sigma(\text{MLP}(\text{AvgPool}(F)) + \text{MLP}(\text{MaxPool}(F))) = \sigma(W_1(W_0(F_{\text{avg}}^C)) + W_1(W_0(F_{\text{max}}^C))) \quad (2)$$

式中: σ 表示 sigmoid 函数; W_1 、 W_0 为全连接层的输出权值; $\text{MLP}(\cdot)$ 表示全连接层计算; $\text{AvgPool}(\cdot)$ 表示全局平均池化计算; $\text{MaxPool}(\cdot)$ 表示全局最大池化计算; F_{avg}^C 和 F_{max}^C 分别表示 F 经过全局平均池化和全局最大池化计算后得到的结果。




图 1 CBAM 的结构

Fig.1 Structure of the CBAM




图2 CAM 的结构

Fig.2 Structure of the CAM

SAM 的结构如图 3 所示, 先对输入特征图从通道维度分别进行平均和最大运算, 然后合并得到一个通道数为 2 的卷积层, 最后通过一层卷积运算, 得到维度为 $1 \times H \times W$ 的空间注意力权重 $M_S(F')$:

$$M_S(F') = \sigma(f^\gamma([\text{AvgPool}(F'); (\text{MaxPool}(F'))]) = \sigma(f^\gamma([F_{\text{avg}}^S; F_{\text{max}}^S])) \quad (3)$$

式中: $f^\gamma[\cdot]$ 表示卷积核大小为 γ 的卷积计算; F_{avg}^S 和 F_{max}^S 分别表示 F' 经过全局平均池化和全局最大池化计算后得到的结果。

综上, 2 种注意力机制通过训练出 2 个变换空间来标记目标特征的位置, 同时增强有用特征的占用比, 为后续网络提供更加精细的信息, 以此有效增强网络提取信息的能力, 进而提升模型的表现。

2 基于 CBAM-CNN 的评估模型设计

2.1 输入特征选取

基于数据的评估方法中, 输入特征集的构建十分关键, 将直接影响评估效果。一般说来, 从故障时刻算起, 特征输入的采样时间窗口越短, 在线评估的响应就越快, 但对稳定评估模型的映射能力要求也越高。本文的目标是建立一种能为电网预防控提供控制的模型, 所选择的特征输入宜不迟于故障发生^[18-19], 且对潮流和扰动位置变化具有适应性。为此, 本文选择发电机稳态有功输出、无功输出, 故障线路编号以及故障发生时刻各节点电压突变值组成输入特征集, 如表 1 所示。表 1 中, n 表示系统节点总数; m 表示机组台数; l 表示线路回数。故障线路编号为一个 l 维的向量, 如第 d 条线路发生三相短路故障, 则第 d 位取 1, 其余为 0。 ΔU 指故障发生时刻节点电压突变值, 可通过自编短路程序快速求得。显然, 输入特征十分简洁, 仅含故障前和故障发生时刻系统的信息。其中, 机组出力反映潮流的变化, 故障位置信息和节点电压突变值反映扰动位置的变化。本文推荐的输入信号对潮流和扰动位置变化高度敏感, 针对性强。




图3 SAM 的结构

Fig.3 Structure of the SAM

表 1 输入特征集

Table 1 Input features

类型	特征量	含义	维度
潮流特征	P_G	机组有功出力	m
	Q_G	机组无功出力	m
故障特征	ΔU	节点电压突变值	n
	F	故障线路编号	l

2.2 模型的输出

本模型输出所有节点的暂态电压稳定水平 φ 和稳定标签 δ 。 φ 的计算式^[20]为:

$$\varphi = \begin{cases} \frac{U_0 - U_{\min}}{U_0 - U_{\text{th}}}, & U_{\min} \geq U_{\text{th}} \\ \frac{T_{\text{mx, span}}}{T_{\text{th}}} + 1, & U_{\min} < U_{\text{th}}, T_{\text{mx, span}} < T_{\text{th}} \\ \frac{T_{\text{mx, span}} - T_{\text{th}}}{T_{\text{end}} - T_{\text{cut}} - T_{\text{th}}} + 2, & T_{\text{mx, span}} \geq T_{\text{th}}, \bar{U}_{\text{end}} \geq U_{\text{th}} \\ \frac{U_{\text{th}} - \bar{U}_{\text{end}}}{U_{\text{th}}} + 3, & \bar{U}_{\text{end}} < U_{\text{th}} \end{cases} \quad (4)$$

式中: U_0 为母线电压初始值; $U_{\min}$ 为故障切除后母线电压的最低值; U_{th} 为预设的电压安全阈值; T_{th} 为短路故障切除后电压低于 U_{th} 的可容忍时间; T_{end} 为仿真总时长; T_{cut} 为故障切除时刻; $T_{\text{mx, span}}$ 为短路故障切除后母线电压低于 U_{th} 的最大持续时间; $\bar{U}_{\text{end}}$ 为仿真结束前 1 s 内电压的平均值。

显然, 指标 φ 的取值范围为 $[0, 4)$; 数值越大, 表示节点暂态电压性能越差。表 2 给出了 φ 的数值在不同区间的含义。可见, $\varphi < 2$ 表示节点暂态电压性能合格, 对应稳定标签 $\delta = 1$; $\varphi > 2$ 表示节点暂态电压性能不满足要求, 对应稳定标签 $\delta = 0$ 。

2.3 模型设计

模型结构如图 4 所示, 由共享层和独立层组成, 应用了硬参数共享(hard parameter sharing, HPS)机制。

共享层包括 CBAM-CNN 网络和全连接层, 参数统一共享。独立层由若干评估子任务组成, 各子任务的输入和模型结构相同, 但参数和输出彼此独立, 目标是同时输出各节点的暂态电压稳定水平和稳定标签。为此, 需要把电网 n 个节点的评估工作

表2 定量指标的物理意义

Table 2 Physical meaning of the quantitative index

范围	对应情形
[0,1)	故障切除后电压一直维持在阈值 U_{th} 以上
[1,2)	电压跌落到 U_{th} 以下, 但持续时间小于阈值 T_{th}
[2,3)	电压低于 U_{th} 的持续时间超过 T_{th} , 但能恢复到 U_{th} 以上
[3,4)	电压跌落到 U_{th} 以下, 且在观察时段不能恢复到 U_{th} 以上

分配至各子任务。经实践, 每个子任务所评估的节点数为 3~5 时, 效果较优。本文推荐的做法是: 先借鉴文献[21]的思路, 用阻抗电气距离描述节点的特征, 再通过谱聚类算法[22]把全部节点划分为 3~5 簇, 使得簇内节点联系紧密、簇间节点联系松散。再把各簇节点分拨给不同的子任务。子任务总数由节点总数除以分类簇数向上取整确定; 分配原则是, 每个子任务评估的节点尽量来自不同簇, 每个子任务评估的节点数尽量多, 但不超过分类簇数。这么做主要是基于以下考虑: 既然各任务共享相同的输入, 那么当各子任务的工作内容也相似时评估效果会更优, 而簇内节点的暂态电压响应一般是相似的。

3 模型训练

3.1 损失函数

由于每个子任务的评估难度有差异, 因此本模型用均方误差作为各子任务的损失函数, 并将总损失函数定义为式(5)所示各子任务损失值的加权和。多任务共同进行反向梯度传播学习, 以缓解模型的过拟合程度, 提升预测精度及泛化能力。

$$\begin{cases} L_{MTL} = \sum_x \lambda_x L_x \\ L_x = \sum_{a=1}^{n_x} (\varphi_{xa} - \varphi'_{xa})^2 / n_x \end{cases} \quad (5)$$

式中: L_{MTL} 为总损失函数; λ_x 为各子任务的损失权重; L_x 为各子任务的损失值; λ_{xa} 和 φ'_{xa} 分别为任务 x 中第 a 个节点稳定水平的实际值和预测值; n_x 为任务 x 的评估节点总数。

为取得最佳的训练效果, 本文采用动态加权平均算法来优化模型中子任务的损失权重, 权值更新计算式为:

$$\begin{cases} \omega_x(e-1) = L_x(e-1) / L_x(e-2) \\ \lambda_x(e) = \frac{k \cdot \exp(\omega_x(e-1)/\epsilon)}{\sum_g \exp(\omega_g(e-1)/\epsilon)} \end{cases} \quad (6)$$

式中: e 表示训练轮次; ω_x 表示训练速度, 数值越




图4 CBAM-CNN 多任务模型结构

Fig.4 CBAM-CNN multi-task model structure

小, 训练越快; ϵ 为温度系数, 用于调控任务分布; k 为系数, 用于划分权重的活动范围。显然, 损失缩小快的任务, 权重也会变小。

3.2 模型的训练

为增强模型的泛化能力, 训练样本应涵盖多样的机组出力方式和故障情景。本文设置的机组出力变化范围较宽, 为额定值的 50%。这么做的原因在于, 本研究力求提供一种对运行方式变化具有适应性的评估模型, 从而为预防控制策略的制订提供参考。本文设置的故障是每条输电线两端发生三相故障, 因为这是最严重的 $N-1$ 故障。故障时节点电压的突变量用自编的短路计算程序快速求得, 该程序基于潮流计算模式, 用戴维南等值法[23]实现。

模型训练均选用 Adam 优化器, 初始学习率为 0.01, 所有样本训练一次更新一次子任务损失权重, 批处理数为 10, 并使用早停策略减少训练量, 保留对测试集评估效果最优的模型。训练过程见图 5。

4 算例分析

本文采用经典 10 机 39 节点系统作为算例。潮流和时域仿真采用电力系统分析软件包 PSD-BPA, CBAM-CNN 多任务模型用 TensorFlow 框架构建。计算条件为 CPU: Intel(R) Core(TM) i5-11400F@2.60 GHz(2 592 MHz), 内存: 16 GB, GPU: NVIDIA GeForce RTX 3060 Ti。

4.1 样本生成

潮流计算中, 每台发电机出力在额定值的 50%~100%之间随机变化, 保留收敛的 1 500 个运行方式。稳定性分析中, 发电机采用详细模型; 负荷

采用综合模型, 恒阻抗和感应电动机负荷各占 50%。该系统共含 34 条交流线路。三相短路是电力系统最严重的故障情形, 评估电力系统暂态电压稳定性通常考虑三相故障。因此, 本文考虑线路两端发生持续 0.12 s 的三相短路, 故障在 1 s 时被切除, U_{th} 和 T_{th} 分别取 0.8(标么值)与 1 s, $\bar{U}_{end}$ 取电压在 [10, 11] s 的平均值。各节点的暂态电压稳定水平和稳定性标签按 2.2 节所述得到。这样, 共生成 $1\,500 \times 34 \times 2$ 即 102 000 个评估样本(即: 1 500 种运行方式下、34 条线路两侧发生三相接地故障), 数量相当大。本文将按其按 9:1 的比例分为训练集及测试集。为更具体评价模型性能, 本文把一种运行方式下一条输电线发生故障称为一个评估样本; 此处样本的概念不同于预防控制中一种运行方式为一个运行样本。

值得注意的是, 故障持续时间为 0.12 s 时训练出来的模型, 不能适应故障持续为 0.08 s、0.10 s 等其他情形。可以按照本文的思路, 为故障持续时间为 0.08 s、0.10 s 等情形各生成一批样本并各训练一个评估模型, 以增强模型的适用性。

4.2 模型结构和参数设置

参照图 4, 本算例 CBAM-CNN 网络分 8 层, 由卷积层、池化层与 CBAM 层组成。第 1 和第 2 层为 1 维卷积层, 卷积数为 16, 卷积核大小为 2, 激活函数为 ReLu; 第 3 层为池化层, 选用 MaxPooling 方式; 第 4 层为 CBAM 层; 第 5 和第 6 层也均为 1 维卷积层, 卷积数为 64, 卷积核大小为 2, 激活函数为 ReLu; 第 7 和第 8 层的结构与第 3 和第 4 层相同。共享全连接层分 2 层, 神经核数量分别为 256 和 128, 激活函数均为 ReLu。独立层各子任务均由 4 个全连接层组成, 前 3 层的神经核数分别为 128, 64 和 32, 激活函数为 ReLu, 第 4 层为输出层。输出层神经核数与该子任务需评估的节点数相同, 激活函数为 Linear。各层具体特征维数如表 3 所示。

4.3 模型性能测试

4.3.1 评价指标

本文用评估 10 000 个样本所需要的时间 T_b 来反映模型的效率, 用平均绝对值误差(mean absolute error, M_{AE})、整体准确率(accuracy, A_{cc})和错判均方差(incorrect geometric mean, I_{GM})来评价模型的性能, 其表达式为:




图 5 模型的训练

Fig.5 Model training

表 3 模型的组成

Table 3 Composition of the model

组成			特征维数
共享层	输入层		93×1
	第 1、2 层	卷积层	93×16
	第 3、4 层	含 CBAM 处理的池化层	46×16
	第 5、6 层	卷积层	46×64
	第 7、8 层	含 CBAM 处理的池化层	23×64
	扁平层		1 472×1
	全连	第 1 层	256×1
独立层	接层	第 2 层	128×1
	子任务全连接层 1		128×1
	子任务全连接层 2		64×1
	子任务全连接层 3		32×1
	子任务输出层		3×1

$$\begin{cases} M_{AE} = \sum_{i=1}^{N_T} \left(\sum_{j=1}^n |\varphi_{ij} - \varphi'_{ij}| / n \right) / N_T \\ A_{cc} = \sum_{i=1}^{N_T} ((r_{si} + r_{ni}) / n) / N_T \\ I_{GM} = \sum_{i=1}^{N_T} \left(\sqrt{\left(\frac{r_{si}^*}{r_{si} + r_{si}^*} \right) \left(\frac{r_{ni}^*}{r_{ni} + r_{ni}^*} \right)} \right) / N_T \end{cases} \quad (7)$$

式中: N_T 为评估样本数; φ_{ij} 和 φ'_{ij} 为样本 i 中节点 j 稳定水平的实际值和预测值; $r_{si}(r_{ni})$ 分别为样本 i 中稳定性标签实际值和预测值同为 1(0)的节点个数; $r_{si}^*(r_{ni}^*)$ 分别为实际值为 1(0)却判为 0(1)的节点个数。

显然, M_{AE} 反映定量评估的精确性, A_{cc} 与 I_{GM} 反映定性分类的准确性。 T_{ts} 、 M_{AE} 、 I_{GM} 越低, A_{cc} 越高, 模型性能越优越。

4.3.2 子任务设计的合理性

根据 2.3 节所述, 在子任务设计中, 本文先用谱聚类算法把系统划分为 3 个分区, 如图 6 所示。可见, 3 个分区分别含有 10、15 和 14 个节点。接着, 把这些节点分配给 13 个子任务, 如表 4 所示。

为验证上述子任务设计方法的合理性, 本文用顺序分配法作为对照。顺序分配法按节点编号依次把 39 个节点分配至 13 个子任务, 即: 节点 1—3 分配给任务 1, 节点 4—6 分配给任务 2, 依此类推。观察图 6 可知, 编号相邻的节点一般彼此临近。也就是说, 每个子任务评估的 3 个节点电压响应是相似的, 这是一种典型的设计方法。2 种设计方案下, 本文按照第 3、4 章所述方法分别构建和训练基于 CBAM-CNN 的多任务暂态电压稳定评估模型。表 5 比较了模型对测试集的评估表现。可见, 本文推荐的子任务设计方法更具优势。

表 6 给出采取分区法、子任务评估节点数分别为 2、3、6 时模型性能的比较。可见, 评估节点数为 3 时, 指标 M_{AE} 、 A_{cc} 和 I_{GM} 均最优, 仅 T_{ts} 为次优。不难理解, 子任务评估节点数较多时, 子任务个数会较少, 模型结构会较为简单, 这有助于提升评估效率。综合而言, 子任务评估节点数为 3 时, 模型性能更优。

4.3.3 动态加权平均策略的效果

图 7 给出迭代过程中部分子任务损失权重 λ 的变化情况。可见, 分区法虽然平衡了任务难度, 但训练初期各子任务的权重还是有所不同。动态加权平均算法通过不断调整模型对各子任务的关注程度, 最终使得各子任务权重 λ_k 收敛于 1, 即各子任务受到均衡的关注, 模型综合学习效果最优。

图 8 给出训练过程中总损失函数的变化曲线, 表明随着训练推进, 误差不断减小。

4.3.4 输入特征集的合理性测试

本节通过控制变量法验证所推荐的输入特征集的优越性, 评估模型均使用 CBAM-CNN 多任务结构, 结果见表 7。表 7 中, 特征组别 1 为本文推荐的输入特征集, 也是参考集。特征组别 2 增加了节点稳态电压 U , 特征组别 3 去掉 ΔU 增加 U , 特征组别 4 去掉故障位置信息 F , 特征组别 5 增加评估节点到故障点的电气距离 d 。可见, 组别 1 评估




图 6 NE-39 节点系统分区结果

Fig.6 NE-39 bus system partition results

表 4 子任务分配结果

Table 4 Tasks allocation

子任务	所评估的节点	节点所属分区
任务 1	(2, 1, 15)	区域 1, 区域 2, 区域 3
任务 2	(3, 4, 16)	区域 1, 区域 2, 区域 3
任务 3	(25, 5, 17)	区域 1, 区域 2, 区域 3
任务 4	(26, 6, 18)	区域 1, 区域 2, 区域 3
任务 5	(27, 7, 19)	区域 1, 区域 2, 区域 3
任务 6	(28, 8, 20)	区域 1, 区域 2, 区域 3
任务 7	(29, 9, 21)	区域 1, 区域 2, 区域 3
任务 8	(30, 10, 22)	区域 1, 区域 2, 区域 3
任务 9	(37, 11, 23)	区域 1, 区域 2, 区域 3
任务 10	(38, 12, 24)	区域 1, 区域 2, 区域 3
任务 11	(14, 13, 33)	区域 2, 区域 2, 区域 3
任务 12	(39, 31, 34)	区域 2, 区域 2, 区域 3
任务 13	(36, 32, 35)	区域 3, 区域 2, 区域 3

表 5 子任务设计方法比较

Table 5 Comparison of different allocation methods

方法	M_{AE}	$A_{cc}/\%$	$I_{GM}/\%$
顺序分配法	0.033 0	98.35	1.62
分区法	0.027 8	98.87	1.03

表 6 子任务评估节点数不同时模型性能比较

Table 6 Comparison of different allocation methods

子任务评估 节点数	M_{AE}	$A_{cc}/\%$	$I_{GM}/\%$	T_{ts}/s
2	0.028 8	98.60	1.23	0.77
3	0.027 8	98.87	1.03	0.72
6	0.030 1	98.42	1.26	0.63

效果最优; ΔU 和故障线路编号是提升评估效果的重要特征, 是必要的; 节点稳态电压 U 和评估节点到故障点的电气距离 d 是冗余特征。




图 7 训练过程中部分子任务权重变化

Fig.7 Changes in part of the task weights during training

4.3.5 评估精度比较

为测试所提模型的性能, 本文设计了其他多任务回归模型以进行比较。对照模型包括: 传统 CNN、人工神经网络(artificial neural network, ANN)、混合注意力层数不同的 CBAM-CNN 模型, 如表 8 所示。其中,CBAM-CNN-2 为本文 2.3 节推荐的评估模型。4 种模型均采用 TensorFlow 框架搭建, 训练数据集统一轮 200 次, 批处理数与优化器等训练参数也相同; 4 种模型还共享本文推荐的特征输入。与需要使用故障后暂态信息的评估模型相比, 上述 4 种模型由于可以更早开始实施评估, 因此具有更高的时效性。

ANN 多任务模型共享层结构为 4 层全连接层, 各层神经元个数分别为 512、256、256、128, 激活函数均为 ReLU, 独立层结构与推荐模型相同。CNN 评估模型的结构与 CBAM-CNN-2 相似, 只是不含 CBAM 层。CBAM-CNN-1 与推荐模型结构基本一致, 区别在于其不含第 8 层的 CBAM。

由表 8 可见, 由于注意力机制 CBAM 有效提升了模型对关键特征的识别与运用能力, 2 种 CBAM-CNN 模型对应的 M_{AE} 、 A_{cc} 和 I_{GM} 指标均更优; 但 CBAM 机制也使得模型复杂度增加, CBAM-CNN 模型的评估效率略低。尽管如此, 本文推荐的 CBAM-CNN-2 模型能满足快速评估的要求, 综合性能最优。

4.3.6 泛化性测试

泛化性是评价模型性能的一个重要指标, 表征了由训练样本训练出的模型对新数据的预测能力。本文随机另外构造了 100 个潮流样本, 并对每种运行方式下输电线路两端发生的故障分别采取推荐模型和对照模型进行泛化测试, 所得结果如表 9 所示。




图 8 训练过程中总损失函数变化

Fig.8 Change in total loss function during training

表 7 输入特征集评估结果比较

Table 7 Comparison of evaluation effect for different input

组别	features							M_{AE}	$A_{cc}/\%$	$I_{GM}/\%$
	P_G	Q_G	U	ΔU	F	d				
1	√	√		√	√		0.027 8	98.87	1.03	
2	√	√	√	√	√		0.033 7	98.28	1.21	
3	√	√	√		√		0.048 6	97.91	1.84	
4	√	√		√			0.078 8	97.13	3.53	
5	√	√		√	√	√	0.030 7	98.43	1.17	

注: √表示是特征输入。

表 8 不同模型对测试集的性能

Table 8 Performance of different models on test samples

模型	M_{AE}	$A_{cc}/\%$	$I_{GM}/\%$	T_{ts}/s
ANN	0.056 7	98.19	1.81	0.49
CNN	0.047 2	98.31	1.79	0.58
CBAM-CNN-1	0.036 7	98.57	1.60	0.65
CBAM-CNN-2	0.027 8	98.87	1.03	0.72

表 9 不同模型对新样本的性能

Table 9 Performance of different models on new samples

模型	M_{AE}	$A_{cc}/\%$	$I_{GM}/\%$
ANN	0.037 5	95.10	6.95
CNN	0.035 0	95.97	7.48
CBAM-CNN-1	0.029 4	96.16	6.45
CBAM-CNN-2	0.019 6	96.48	5.58

可见, CBAM-CNN-2 的指标优于其他模型, 表明 CBAM-CNN-2 具有更优秀的泛化能力。

4.3.7 讨论

如前所述, 本文推荐的基于 CBAM-CNN 的暂态电压稳定评估模型既可实现定量评估, 也可间接实现定性评估, 且定量和定性评估的准确性均较高, 因此能为失稳区域识别和电压稳定控制策略制订提供更充分的参考。

表 10 给出某个样本的定量/定性评估结果与真

表 10 样本评估结果真实值与输出值比较
Table 10 Comparison of real value and estimate of sample evaluation result

节点编号	稳定水平 φ		稳定标签 δ	
	真实值	预测值	真实值	预测值
1	3.201	3.114	0	0
2	2.081	2.027	0	0
3	2.033	2.065	0	0
4	2.022	2.073	0	0
5	2.008	2.036	0	0
6	2.000	1.947	0	1
7	2.015	2.044	0	0
8	2.018	2.024	0	0
9	0.880	0.960	1	1
10	1.350	1.309	1	1
11	1.475	1.408	1	1
12	2.009	2.037	0	0
13	1.525	1.392	1	1
14	2.004	1.842	0	1
15	1.900	1.895	1	1
16	1.325	1.343	1	1
17	2.009	2.002	0	0
18	2.023	2.053	0	0
19	0.755	0.716	1	1
20	0.959	0.969	1	1
21	0.962	0.962	1	1
22	0.730	0.760	1	1
23	0.759	0.739	1	1
24	1.250	1.190	1	1
25	2.024	2.005	0	0
26	2.011	2.012	0	0
27	2.014	2.003	0	0
28	1.900	1.785	1	1
29	1.625	1.396	1	1
30	1.350	1.275	1	1
31	0.894	0.905	1	1
32	0.851	0.866	1	1
33	0.709	0.678	1	1
34	0.896	1.132	1	1
35	0.560	0.614	1	1
36	0.567	0.660	1	1
37	1.850	1.942	1	1
38	1.250	1.355	1	1
39	0.935	0.933	1	1

实值的比较。可见，本模型的评估精度总体很高，但节点 6 和 14 的定性评估结果与真实值相悖。进一步对测试集 10 200 个评估样本中所有定性错判节点的数据进行了统计分析，发现约 87%定性错判节点的真实稳定水平在 1.9~2.1 之间，约 95%定性错判节点的真实稳定水平在 1.8~2.2 之间，定性错判节点稳定水平预测值与真实值的平均误差为 0.083 1 (高于 M_{AE})。以上结果表明，定性错判大多发生在节点电压稳定水平真实值接近于 2 时(表 10 中节点

6 与 14 就是这种情况)。可见，定量评估结果在临界值附近时，结果的可靠性降低，有待进一步研究和解决。

5 结论

1) 所提出的模型以电网稳态运行信息、故障位置信息和电压突变信息为输入特征，评估时效性高，对机组出力变化和故障位置变化具有充分的适应性。

2) 所提出的评估模型子任务设计合理，所采取的动态加权平均策略能均衡模型对各子任务的关注程度，实现电网多节点暂态电压稳定水平和稳定标签的准确预测。

3) 与几种经典深度学习模型相比，所提出的模型有更强的信息表征能力和泛化能力，评估结果误差更小、准确率更高。

下一步的研究方向是提出针对多节点暂态电压稳定定量评估结果的评价及核查机制，并将模型应用于电网预防控制策略的制订中。

参考文献 References

[1] 朱益华, 饶 宏, 郭 琦, 等. 改善局部电网暂态电压稳定特性的 LCC-HVDC 控制策略优化[J]. 高电压技术, 2024, 50(7): 2809-2819. ZHU Yihua, RAO Hong, GUO Qi, et al. Optimization of LCC-HVDC control strategy for improving transient voltage stability characteristics of partial power grids[J]. High Voltage Engineering, 2024, 50(7): 2809-2819.

[2] 张祥宇, 赵欣艳, 付 媛, 等. 直流微网的多端暂态电压主动支撑控制技术[J]. 高电压技术, 2022, 48(10): 4006-4016. ZHANG Xiangyu, ZHAO Xinyan, FU Yuan, et al. Multi-terminal transient voltage active support control technology for DC microgrid[J]. High Voltage Engineering, 2022, 48(10): 4006-4016.

[3] 蔡 旭, 秦 垚, 王 晗, 等. 风电机组的自同步电压源控制研究综述[J]. 高电压技术, 2023, 49(6): 2478-2490. CAI Xu, QIN Yao, WANG Han, et al. Review of Self-synchronous voltage source control for wind turbine generator[J]. High Voltage Engineering, 2023, 49(6): 2478-2490..

[4] 上官鑫, 秦文萍, 夏福良, 等. 基于暂态电压 Pearson 相关性的 MMC 多端柔性直流配电网单极接地故障保护方案[J]. 高电压技术, 2020, 46(5): 1740-1749. SHANGGUAN Xin, QIN Wenping, XIA Fuliang, et al. Pole-to-ground fault protection scheme for MMC multi-terminal flexible DC distribution network based on Pearson correlation of transient voltage[J]. High Voltage Engineering, 2020, 46(5): 1740-1749.

[5] 管 霖, 黄济宇, 蔡锴涵, 等. 图深度学习技术在电力系统分析与决策领域的应用与展望[J]. 高电压技术, 2022, 48(9): 3405-3422. GUAN Lin, HUANG Jiyu, CAI Zihan, et al. Application and prospect of graph deep learning technique in power system analysis and decision[J]. High Voltage Engineering, 2022, 48(9): 3405-3422.

[6] 甘国晓, 耿光超, 仲悟之, 等. 电力系统暂态稳定紧急控制并行序贯优化算法[J]. 电力自动化设备, 2018, 38(8): 68-73.

- GAN Guoxiao, GENG Guangchao, ZHONG Wuzhi, et al. Parallel sequential optimization algorithm for transient stability emergency control of power system[J]. Electric Power Automation Equipment, 2018, 38(8): 68-73.
- [7] 史法顺, 吴俊勇, 吴昊衍, 等. 基于深度学习的电力系统暂态功角与暂态电压稳定裕度一体化评估[J]. 电网技术, 2023, 47(2): 731-740.
- SHI Fashun, WU Junyong, WU Haoyan, et al. Integrated evaluation of power system transient power angle and transient voltage stability margin based on deep learning[J]. Power System Technology, 2023, 47(2): 731-740.
- [8] 王长江, 姜 涛, 陈厚合, 等. 基于相位校正李雅普诺夫指数的电力系统暂态电压稳定评估[J]. 电工技术学报, 2021, 36(15): 3221-3236.
- WANG Changjiang, JIANG Tao, CHEN Houhe, et al. Transient voltage stability assessment of power systems based on phase correction maximum Lyapunov exponent[J]. Transactions of China Electrotechnical Society, 2021, 36(15): 3221-3236.
- [9] XU Y, ZHANG R, ZHAO J H, et al. Assessing short-term voltage stability of electric power systems by a hierarchical intelligent system[J]. IEEE Transactions on Neural Networks and Learning Systems, 2016, 27(8): 1686-1696.
- [10] ZHU L P, LU C, SUN Y Z. Time series shapelet classification based online short-term voltage stability assessment[J]. IEEE Transactions on Power Systems, 2016, 31(2): 1430-1439.
- [11] 朱利鹏, 陆 超, 黄 河, 等. 基于时序轨迹特征学习的暂态电压稳定评估[J]. 电网技术, 2019, 43(6): 1922-1930.
- ZHU Lipeng, LU Chao, HUANG He, et al. Transient voltage stability assessment based on sequential trajectory feature learning[J]. Power System Technology, 2019, 43(6): 1922-1930.
- [12] 陈 达, 朱 林, 张 健, 等. 基于卷积神经网络的暂态电压稳定评估及风险量化[J]. 电力系统自动化, 2021, 45(14): 65-71.
- CHEN Da, ZHU Lin, ZHANG Jian, et al. Transient voltage stability assessment and risk quantification based on convolutional neural network[J]. Automation of Electric Power Systems, 2021, 45(14): 65-71.
- [13] 杨维全, 朱元振, 刘玉田. 基于卷积神经网络的暂态电压稳定快速评估[J]. 电力系统自动化, 2019, 43(22): 46-51.
- YANG Wei-quan, ZHU Yuan-zhen, LIU Yutian. Fast assessment of transient voltage stability based on convolutional neural network[J]. Automation of Electric Power Systems, 2019, 43(22): 46-51.
- [14] 来文青, 龚庆武, 高春辉, 等. 基于特征量和卷积神经网络的暂态电压稳定评估[J]. 武汉大学学报(工学版), 2019, 52(9): 815-823, 835.
- LAI Wenqing, GONG Qingwu, GAO Chunhui, et al. Transient voltage stability evaluation based on feature and convolutional neural network[J]. Engineering Journal of Wuhan University, 2019, 52(9): 815-823, 835.
- [15] HAGMAR H, TONG L, ERIKSSON R, et al. Voltage instability prediction using a deep recurrent neural network[J]. IEEE Transactions on Power Systems, 2021, 36(1): 17-27.
- [16] 孙黎霞, 彭嘉杰, 白景涛, 等. 结合图嵌入算法的电力系统多任务暂态稳定评估[J]. 电力系统自动化, 2022, 46(2): 83-91.
- SUN Lixia, PENG Jiajie, BAI Jingtao, et al. Multi-task transient stability assessment of power system incorporating graph embedding algorithm[J]. Automation of Electric Power Systems, 2022, 46(2): 83-91.
- [17] WOO S, PARK J, LEE J Y, et al. CBAM: convolutional block attention module[C]//Proceedings of the 15th European Conference on Computer Vision. Munich, Germany: Springer, 2018: 3-19.
- [18] 朱 林, 张 健, 陈 达, 等. 面向暂态电压稳定评估的卷积神经网络输入特征构建方法[J]. 电力系统自动化, 2022, 46(1): 85-93.
- ZHU Lin, ZHANG Jian, CHEN Da, et al. Construction method for input features of convolutional neural network for transient voltage stability assessment[J]. Automation of Electric Power Systems, 2022, 46(1): 85-93.
- [19] 房佳姝, 刘崇茹, 苏晨博, 等. 基于自注意力 Transformer 编码器的多阶段电力系统暂态稳定评估方法[J]. 中国电机工程学报, 2023, 43(15): 5745-5759.
- FANG Jiashu, LIU Chongru, SU Chenbo, et al. Multi-stage transient stability assessment of power system based on self-attention Transformer encoder[J]. Proceedings of the CSEE, 2023, 43(15): 5745-5759.
- [20] 林银鸿, 王 彬, 葛怀畅, 等. 电网在线暂态电压安全分析的降维方法[J]. 电力系统自动化, 2021, 45(12): 109-118.
- LIN Yinhong, WANG Bin, GE Huaichang, et al. Dimension reduction method for online transient voltage security analysis of power grid[J]. Automation of Electric Power Systems, 2021, 45(12): 109-118.
- [21] MAO X M, ZHU W F, WU L, et al. Comparative study on methods for computing electrical distance[J]. International Journal of Electrical Power & Energy Systems, 2021, 130: 106923.
- [22] VON LUXBURG U. A tutorial on spectral clustering[J]. Statistics and Computing, 2007, 17(4): 395-416.
- [23] 何仰赞, 温增银. 电力系统分析(上)[M]. 4 版. 武汉: 华中科技大学出版社, 2016: 120-125.
- HE Yangzan, WEN Zengyin. Power system analysis (part I)[M]. 4th ed. Wuhan, China: Huazhong University of Science and Technology Press, 2016: 120-125.



RONG Jingchao



MAO Xiaoming

Ph.D.

Associate professor

Corresponding author

收稿日期 2023-09-13 修回日期 2024-02-15 编辑 何秋萍

容景超

1999—, 男, 硕士生

主要研究方向为电力系统稳定性分析与控制

E-mail: 15625152781@163.com

毛晓明(通信作者)

1971—, 女, 博士, 副教授

主要研究方向为电力系统运行分析与控制

E-mail: mxmsunny@163.com